

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# **ZAVRŠNI RAD**

**Jasmina PREMEC**

Zagreb, 2014.

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# ZAVRŠNI RAD

*Voditelj rada:*

Prof.dr.sc. Dubravko MAJETIĆ

*Student:*

Jasmina PREMEC

Zagreb, 2014.

*Izjavljujem da sam ovaj rad izradila samostalno koristeći stečena znanja tijekom studija i navedenu literaturu.*

*Eksperimentalni dio rada provela sam u laboratorijima Sveučilišta Paderborn, Fakulteta strojarstva, odjela za Mehatroniku i dinamiku, kojima se zahvaljujem na financiranju i opremi. Posebno se zahvaljujem mentoru M.sc. Jamesu Kuria Kimotho, pod čijim mentorstvom sam provela eksperimente, na vodstvu, stručnim savjetima i strpljenju.*

*Srdačno se zahvaljujem voditelju rada prof.dr.sc. Dubravku Majetiću na prihvatanju mentorstva za ovaj rad, pružanju korisnih savjeta te stručne pomoći pri izradi rada.*

*Jasmina Premec*

# Sadržaj

<b>Sadržaj</b>	<b>i</b>
<b>Popis slika</b>	<b>iii</b>
<b>Popis tablica</b>	<b>v</b>
<b>Popis oznaka</b>	<b>vi</b>
<b>Sažetak</b>	<b>viii</b>
<b>Summary</b>	<b>ix</b>
<b>1 Uvod</b>	<b>1</b>
<b>2 Piezoelektrični bimorfni pretvornik</b>	<b>3</b>
2.1 Piezoelektrični efekt . . . . .	3
2.1.1 O efektu . . . . .	3
2.1.2 Matematička reprezentacija efekta . . . . .	4
2.1.3 Piezoelektrični materijali . . . . .	5
2.1.4 Primjena . . . . .	5
2.2 O pretvorniku . . . . .	6
<b>3 Eksperiment</b>	<b>9</b>
3.1 Uvod i oprema . . . . .	9
3.2 Eksperiment 1 . . . . .	11
3.2.1 Provedba eksperimenta 1 . . . . .	11
3.2.2 Analiza eksperimenta 1 . . . . .	12
3.3 Eksperiment 2 . . . . .	15
3.3.1 Provedba eksperimenta 2 . . . . .	15
3.3.2 Analiza eksperimenta 2 . . . . .	17
3.4 Eksperiment 3 . . . . .	18
3.4.1 Provedba eksperimenta 3 . . . . .	18
3.4.2 Analiza eksperimenta 3 . . . . .	19
<b>4 Izgradnja i verifikacija matematičkog modela piezoelektričnog pretvornika</b>	<b>22</b>
4.1 Matematički model pretvornika . . . . .	22
4.2 Izračun ekvivalentnih parametara modela . . . . .	24
4.3 Verifikacija matematičkog modela . . . . .	27
<b>5 Primjena statičkih neuronskih mreža u praćenju degradacije pretvornika</b>	<b>29</b>
5.1 Uvod u umjetne neuronske mreže . . . . .	29
5.1.1 Biološki i umjetni neuron . . . . .	29
5.1.2 Osnovne podjele umjetnih neuronskih mreža . . . . .	30
5.2 Statička neuronska mreža . . . . .	31
5.2.1 Unaprijedna faza učenja . . . . .	33
5.2.2 Povratna faza učenja . . . . .	34



5.2.3	Algoritam povratnog rasprostiranja pogreške (Error Back Propagation) . . . . .	35
5.2.4	Levenberg - Marquardt algoritam . . . . .	38
5.3	Aproksimacija pomaka na temelju mjerenog napona . . . . .	42
5.4	Aproksimacija rezonantne frekvencije i ekvivalentnog otpora . . . . .	48
<b>Zaključak</b>		<b>51</b>
<b>Literatura</b>		<b>52</b>

## Popis slika

1.1	Epiezoelektrični uređaji, a)duo-unimorfna prihvatnica, b)duo-bimorfna prihvatnica MOC (eng. Microrobot On Chip), c)radna ploča s piezoelektričnom prihvatnicom . . . . .	1
2.1	Prikaz piezoelektričnog efekta . . . . .	3
2.2	a)kristal kvarca; b)neopterećeni kristal; c)opterećeni kristal duž $x$ -osi; d)opterećeni kristal duž $y$ -osi . . . . .	4
2.3	Piezosenzor - princip rada . . . . .	5
2.4	Piezoaktuator - princip rada . . . . .	6
2.5	Bimorfni pretvornik: princip rada . . . . .	6
2.6	Shema bimorfnog pretvornika . . . . .	6
2.7	Pretvornik - prikaz rada . . . . .	7
2.8	Vrste grednih pretvornika . . . . .	7
2.9	Provodnost (eng. <i>admittance</i> ) pretvornika kod karakterističnih frekvencija . . . . .	8
3.1	Piezoelektrični pretvornik, geometrijske značajke . . . . .	9
3.2	Oprema . . . . .	10
3.3	Oprema . . . . .	10
3.4	Eksperiment . . . . .	11
3.5	Napon na senzorskoj strani - jedno uzorkovanje . . . . .	12
3.6	Napon na senzorskoj strani kroz 12 sati . . . . .	12
3.7	Promjena amplitudnih vrijednosti senzorskog napona svih uzoraka . . . . .	13
3.8	Mjerena brzina i pomak jednog uzorkovanja . . . . .	13
3.9	Pomak pretvornika kroz 12 sati . . . . .	14
3.10	Promjena amplitudnih vrijednosti pomaka kroz 12 sati . . . . .	14
3.11	Analiza električne vodljivosti ( <i>admittance</i> ) pretvornika . . . . .	15
3.12	Električna vodljivost (eng. <i>admittance</i> ) pretvornika s parametrima . . . . .	16
3.13	Promjena rezonantne frekvencije kroz mjerenja . . . . .	17
3.14	Promjena ekvivalentnog otpora kroz mjerenja . . . . .	17
3.15	Mjerena električna vodljivost pretvornika prije i nakon loma (crno - prije, crveno - poslije) . . . . .	18
3.16	Ulazni signal mjeren osciloskopom . . . . .	19
3.17	Pretvornik . . . . .	19
3.18	Analiza signala senzorskog napona . . . . .	20
3.19	Analiza parametara dobivenih analizom električne vodljivosti . . . . .	21
4.1	Ekvivalentni model u a) mehaničkom i b) električnom prikazu . . . . .	22
4.2	SIMULINK model piezoelektričnog pretvornika . . . . .	28
4.3	Usporedba mjerenog i simuliranog signala . . . . .	28
5.1	Pojednostavljena struktura biološkog neurona . . . . .	29
5.2	Struktura umjetnog neurona . . . . .	30
5.3	Nelinearna bipolarna sigmoidalna aktivacijska funkcija . . . . .	32
5.4	Model statičke unaprijedne neuronske mreže . . . . .	33
5.5	Topologija trenirane statičke neuronske mreže . . . . .	43
5.6	Parametri treniranja mreže . . . . .	43
5.7	Usporedba mjerenog i izlaznog signala . . . . .	44
5.8	Usporedba mjerenog i izlaznog signala kod amplitudnih vrijednosti . . . . .	45
5.9	Usporedba mjerenog i izlaznog signala . . . . .	45
5.10	Usporedba mjerenog i izlaznog signala kod amplitudnih vrijednosti . . . . .	46

5.11 Blok shema testiranja mreže . . . . .	47
5.12 Usporedba mjenog i izlaznog signala kod amplitudnih vrijednosti . . . . .	47
5.13 Topologija mreže . . . . .	48
5.14 Parametri treniranja mreže LM algoritmom . . . . .	48
5.15 Rezonantna frekvencija . . . . .	49
5.16 Ekvivalentni otpor . . . . .	49
5.17 Parametri treniranja mreže EBP algoritmom . . . . .	49
5.18 Rezonantna frekvencija . . . . .	49
5.19 Ekvivalentni otpor . . . . .	49

**Popis tablica**

2.1	Parametri pretvornika . . . . .	8
3.1	Parametri eksperimentalnog pretvornika . . . . .	9
4.1	Veličine dobivene od proizvođača za materijal M1876 . . . . .	27
4.2	Parametri pretvornika dobiveni na temelju (4.13) - (4.30) . . . . .	27

## Popis oznaka

Oznaka	Jedinica	Opis
$D$	$C/m^2$	gustoća električnog toka
$\varepsilon$	F/m	dielektričnost
$E$	V/m	jakost električnog polja
$S$	-	deformacija
$s$	$m^2/N$	neotpornost
$T$	$N/m^2$	naprezanje
$l_b$	mm	ukupna duljina pretvornika
$l$	mm	slobodna duljina pretvornika
$w$	mm	širina pretvornika
$t$	mm	debljina pretvornika
$y$	mm	ukupni otklon
$F_b$	mN	sila na pojedinoj strani pretvornika
$C$	nF	kapacitet pojedine keramičke strane
$U_{max}$	V	radni napon
$f_m$	Hz	frekvencija minimalne impedancije
$f_s$	Hz	frekvencija serijske rezonance
$f_r$	Hz	rezonantna frekvencija
$f_n$	Hz	frekvencija maksimalne impedancije
$f_p$	Hz	frekvencija paralelne rezonance
$f_a$	Hz	antirezonantna frekvencija
$t_p$	mm	debljina piezosloja
$t_{sh}$	mm	debljina međusloja
$R_m$	$\Omega$	ekvivalentni otpor
$L_m$	mH	ekvivalentni induktivitet
$C_m$	pF	ekvivalentni kapacitet
$C_p$	nF	kapacitet piezoelektričnog sustava
$Q_m$	-	faktor mehaničke kvalitete
$x$	m	pomak
$F$	N	sila
$M$	kg	ekvivalentna masa
$B$	Ns/m	ekvivalentno mehaničko prigušenje
$K$	N/m	ekvivalentna mehanička krutost
$\alpha$	-	prijenosni faktor
$k$	-	piezoelektrični faktor spoja
$Y_b$	$N/m^2$	modul elastičnosti grede
$I_b$	$m^4$	moment inercije grede

$Y_p$	N/m <sup>2</sup>	modul elastičnosti piezokeramičkog sloja
$Y_{sh}$	N/m <sup>2</sup>	modul elastičnosti međusloja
$Y_{bsc}$	N/m <sup>2</sup>	modul elastičnosti pretvornika kod donje granice krutosti
$Y_{boc}$	N/m <sup>2</sup>	modul elastičnosti pretvornika kod gornje granice krutosti
$I_{bsc}$	m <sup>4</sup>	moment inercije pretvornika za donju granicu krutosti
$I_{boc}$	m <sup>4</sup>	moment inercije pretvornika za gornju granicu krutosti
$K_{bsc}$	N/m	donja granica krutosti
$K_{boc}$	N/m	gornja granica krutosti
$M_b$	kg	masa pretvornika
$\rho_p$	kg/m <sup>3</sup>	gustoća piezokeramičkog sloja
$\rho_{sh}$	kg/m <sup>3</sup>	gustoća međusloja
$net$	-	vrijednost funkcije sume
$y$	-	vrijednost izlaza neurona
$Z_i$	-	ulazi u mrežu
$v_{ij}$	-	težine veza između ulaznog i skrivenog sloja
$w_{kj}$	-	težine veza između skrivenog i izlaznog sloja
$O_k$	-	izlazi iz mreže
BIAS	-	neuroni izlazne vrijednosti jednake jedinici
$H$	-	oznaka skrivenog sloja
$I$	-	broj ulaznih neurona + 1
$J$	-	broj neurona u skrivenom sloju + 1
$K_p$	-	nagib lienarne aktivacijske funkcije
$E$	-	greška učenja
$d_n$	-	željeni izlazi
$N$	-	broj koraka u skupu za učenje
$\vartheta$	-	težinski koeficijenti
$\eta$	-	koeficijent učenja mreže
$\alpha$	-	momentum
$J(\mathbf{w})$	-	Jacobieva matrica

## Sažetak

Piezoelektrični bimorfni pretvornik elektronički je element koji ima široku namjenu u raznim uređajima. Najčešće se koristi kao aktuator za pozicioniranje na mikrometarskoj razini, zbog čega je bitno uočiti promjenu bilo koje vrste u parametrima koji utječu na promjenu vrijednosti pomaka. U ovom radu opisan je piezoelektrični bimorfni pretvornik, njegova struktura, parametri, način rada, svojstva. Izveden je i matematički model pretvornika te provedena simulacija istog u odgovarajućem softverskom paketu. Zatim su opisana tri eksperimenta provedena na pretvornicima istog tipa te je dana analiza rezultata. Primjenjena je umjetna neuronska mreža u svrhu aproksimiranja parametara čijom analizom je moguće utvrditi stanje pretvornika. Parametri se aproksimiraju na temelju lako mjerljivih veličina poput napona i struje te se tako izbjegava prekid rada uređaja i korištenje skupocjenih senzora. Korištenjem umjetnih neuronskih mreža moguće je dobiti uvid u broj preostalih radnih sati pretvornika prije nego dođe do zamora materijala te zakazati pravovremeno održavanje. Također je moguće utvrditi lom ili neki drugi oblik kvara pretvornika.

**Ključne riječi:** piezoelektrični bimorfni pretvornik, aktuator, pozicioniranje, eksperimenti, matematički model pretvornika, umjetna neuronska mreža, zamor piezoelektričnog materijala, lom, kvar.

## Summary

Piezoelectric bimorph transducer is an electronic component that has wide application in various devices. Since it is generally used as an actuator for positioning on a micrometer scale, it is important to determine any kind of change in properties that effect the displacement of the transducer. In this paper piezoelectric bimorph transducer is described, its structure, parameters, mode of work and properties are given. Mathematical model of the transducer is described, also simulation of the model in proper software package is conducted. Three experiments are executed on transducers of the same type, and analysis of the results is given. Artificial neural network is used to approximate parameters that are relevant for determining condition of the transducer. Parameters are approximated based on values that can be measured easily, such as voltage or current. By using artificial neural networks it is possible to get insight in remaining working hours of the transducer before it comes to fatigue, therefore it is possible to schedule maintenance on time. Furthermore, cracks or any other type of failure can be determined.


**Key words:** piezoelectric bimorph transducer, actuator, positioning, experiments, mathematical model of the transducer, artificial neural network, fatigue, crack, failure.



## 1 Uvod

Piezoelektrični bimorfni pretvornici elektronički su elementi koji se koriste kao senzori i kao aktuatori zbog reverzibilne karakteristike piezoelektričnog efekta, a svojim su djelovanjem slični bimetalima. Kako konstrukcija piezoelektričnih bimorfnih pretvornika omogućuje otklon od nekoliko milimetara, sile do nekoliko Newtona, ostvarene u vrlo kratkom vremenskom periodu, piezoelektrični bimorfni pretvornik smatra upravljačkim elementom visoke djelotvornosti i brze reakcije. Piezoelektrični bimorfni gredni aktuatori niskonaponski su elementi, imaju veliku brzinu upravljanja, tihi su i ne zahtijevaju puno prostora, što ih čini široko rasprostranjenim u raznim primjenama. Specifični dizajn aktuatora zajedno s učinkovitom keramikom uspješno postiže regulaciju otklona i sile.

Upotreba piezoelektričnih pretvornika u aktuatorskom modu rada najčešća je kod pozicioniranja na mikro/nanometarskoj skali. Primjer primjene je piezoprihvatnica (slika 1.1a, b)) korišten za mikromanipulaciju ili mikromontažu sitnih dijelova, poput bioloških objekata ili mikrostrukture (slika 1.1c)).



Slika 1.1: Epiezoelektrični uređaji, a)duo-unimorfna prihvatnica, b)duo-bimorfna prihvatnica MOC (eng. Micro-robot On Chip), c)radna ploča s piezoelektričnom prihvatnicom

U aktuatorskom modu rada potrebno je unaprijediti pouzdanost pretvornika kontinuiranim praćenjem stanja prilikom radnih uvjeta, jer tijekom radnog vijeka dolazi do zamora materijala što uzrokuje promjene u preciznosti pretvornika, smanjen iznos postignutog otklona i sile. Najrasprostranjenija metoda za praćenje je analizom svojstvenih parametara pretvornika

korištenjem uređaja za analizu impedancije. Ipak, to nije uvijek najpraktičnija metoda testiranja tijekom rada s obzirom da zahtjeva prekid rada, a najčešće i odvajanje piezoelemenata od ostatka konstrukcije da bi se mogli podatci pravilno izmjeriti. Stoga je potrebno razviti alternativnu metodu za utvrđivanje i praćenje degradacije, a dobiveni podaci mogli bi se koristiti za praćenje degradacije te u skladu s time pravovremeno održavanje čime bi se spriječio nepravilan rad uređaja.


Jedna od metoda za jednostavnije praćenje degradacije piezoelektričnog pretvornika je korištenje umjetnih neuronskih mreža. Mrežama je moguće na temelju dostupnih signala, primjerice napona i struje, aproksimirati parametre za čije mjerenje bi bili potrebni skupocjeni senzori i prekid rada. Na temelju tih parametara moguće je procijeniti stanje pretvornika.

## 2 Piezoelektrični bimorfni pretvornik

### 2.1 Piezoelektrični efekt

#### 2.1.1 O efektu

Piezoelektricitet je električni naboj koji se generira kao reakcija na mehaničko naprezanje. Kada je na piezoelektrični materijal narinuta mehanička sila generira se električni naboj, isto tako dolazi do mehaničkog naprezanja prilikom narinutog električnog napona. Reverzibilnost ove pojave posljedica je simetrije u kristalima.




Slika 2.1: Prikaz piezoelektričnog efekta

Piezoelektricitet su otkrili Jacques i Pierre Curie 1880. godine. Primjenjujući silu na kristal u određenim smjerovima, otkrivena je pojava električnih polova različitih predznaka na suprotnim krajevima kristala. Godinu poslije potvrdili su i postojanje suprotnog efekta. Prva praktična primjena piezoelektričnog efekta bila je za vrijeme Prvog svjetskog rata, kada su proizvedeni prvi sonarni uređaji za otkrivanje podmornica. Kako su otkrivani novi piezoelektrični materijali, unaprijeđivano je i teorijsko razumijevanje pojave. Danas se i dalje razvijaju nove tehnološke primjene i otkrivaju novi piezoelektrični materijali.

Piezoelektrični materijal u prisustvu električnog polja na molekularnoj razini stvara dipolni moment, odnosno krajevi molekula imaju različite naboje, koji se manifestiraju kao površinski naboj. Dipolni momenti kristala simetrično su orijentirani tako da je on nepolaran, ali njegovim stlačenjem ukupnom zbroju dipolnih momenata preostaje dio vertikalne komponente. Ovaj proces najjednostavnije je objašnjen na primjeru kristala kvarca. Kada kristal nije mehanički napregnut, svi električni naboji su u ravnoteži (slika 2.2 b)). Ako u smjeru osi  $x$

djeluje sila  $F_1$  (slika 2.2 c)), narušava se ravnoteža i kao rezultat na elektrodama se javlja elektrostatički naboj. Ako se djeluje silom  $F_2$  duž osi  $y$ , ponovno će se javiti električni naboj na istim elektrodama, ali sa suprotnim predznakom (slika 2.2 d)).



Slika 2.2: a) kristal kvarca; b) neopterećeni kristal; c) opterećeni kristal duž x-osi; d) opterećeni kristal duž y-osi

Spajanjem gornje i donje strane kristala na elektrode i uključivanjem ampermetra u krug, detektira se protok naboja. Kada se jednom naboj odvede s površine dielektrika, unutar kristala nastaje nova ravnoteža, tj. ukupni dioplni momenti molekula iščezavaju, stoga stalan tlak na piezoelektrik neće proizvoditi stalnu struju.

### 2.1.2 Matematička reprezentacija efekta

Piezoelektricitet je spoj električne karakteristike materijala:

$$D = \epsilon E$$

gdje je  $D \frac{C}{m^2}$  gustoća električnog toka,  $\epsilon \frac{F}{m}$  dielektričnost,  $E \frac{V}{m}$  jakost električnog polja te mehaničke karakteristike materijala:

$$S = sT$$

gdje je  $S$  deformacija,  $s$  neotpornost (eng. *compliance*) i  $T$  naprezanje.

Navedene jednačbe mogu biti kombinirane u tzv. spregnute jednačbe, odnos deformacija-naboj:

$$S = [s^E]T + [d]E \quad (2.1)$$

$$D = [d^t]T + [\epsilon^T]E \quad (2.2)$$

gdje je  $[d]$  matrica direktnog piezoelektričnog efekta, a  $[d^t]$  matrica reverznog piezoelektričnog efekta. Gornji indeks  $E$  označava nulto ili konstantno električno polje, dok gornji indeks  $T$  označava nulto ili konstantno polje naprezanja.

### 2.1.3 Piezoelektrični materijali

Kao piezoelektrični materijali koriste se:


- kristali - kvarc, litijski niobat, Rochellova sol, litijski tantalid i drugo,
- keramika - najčešći strukturni tip izgrađen je od oksigen-oktaedara u kutovima (eng. *corner-sharing oxigen-octahedra*). Primjeri piezoelektrične keramike koje imaju ovu strukturu su barijev titanat ( $\text{BaTiO}_3$ ), olovni titanat ( $\text{PbTiO}_3$ ) i drugi,
- piezoelektrični polimeri - npr. polivinildilenski florid (PVDF).

Postoje i kombinacije keramike i polimera.


### 2.1.4 Primjena

Primjena uređaja koji rade na principu piezoelektričnog efekta vrlo je rasprostranjena. Neki od primjera su električni upaljač, gdje mu je svrha generiranje električne energije, zatim u raznim sonarnim uređajima, oscilatorima koji služe kao generatori takta u računalima, zvučnicima, tintnim pisačima i slično. Također je jedna od primjena piezoelektričnog efekta u prikupljanju energije iz okolnih vibracija (eng. *energy harvesting*) poput ljudskog hoda, ili vibracija uzrokovanih industrijskim strojevima, gdje se prikupljena energija skladišti u baterije te se napajaju uređaji niskog napona poput mikrokontrolera ili bežičnih radio uređaja. Kombinacija piezoelektrika se može koristiti i za uklanjanje neželjenih vibracija kod preciznih uređaja, tako da jedan piezoelektrik otkriva vibracije, a drugi emitira vibracije koje ih poništavaju.

Piezoelektrični efekt zbog svojeg reverzibilnog svojstva ima široku upotrebu kao senzor i kao aktuator.



Slika 2.3: Piezosenzor - princip rada



Slika 2.4: Piezoaktuator - princip rada


Jedan od uređaja koji također služi kao aktuator i kao senzor je piezoelektrični bimorfni pretvornik.

## 2.2 O pretvorniku

Dvije povezane piezoelektrične keramičke ploče zajedno s međuslojem, na koje je narinut napon, rezultiraju deformacijom konstrukcije, sličnom deformaciji strukture bimetala. Na ploče je narinut napon suprotne polarizacije, tako da u istom trenutku na gornjoj ploči pojavljuje tlak, a na donjoj vlak (slika 2.5) što rezultira otklonom određenog iznosa. Promjenom polarizacije dolazi do otklona u suprotnom smjeru.




Slika 2.5: Bimorfni pretvornik: princip rada




Slika 2.6: Shema bimorfnog pretvornika

Na slici 2.7 prikazan je rad pretvornika, gdje žute ploče simboliziraju elektrode, narančaste piezokeramiku a crne vezivni sloj metala, međusloj, koji između ostalog služi kao vodič.



Slika 2.7: Pretvornik - prikaz rada

Gredni pretvornik sastavljen od dva sloja piezokeramike sa središnjim slojem između naziva bimorf. Također postoje i multimorfni gredni aktuatori koji uključuju nekoliko aktivnih slojeva, pa tako i monomorfni gredni aktuatori, gdje postoji samo jedan sloj piezokeramike zajedno sa slojem metala. (slika 2.8).



Slika 2.8: Vrste grednih pretvornika

Piezoelektrični bimorfni gredni pretvornici karakterizirani su sljedećim parametrima: materijal, ukupna duljina, slobodna duljina, širina, debljina, ukupni otklon, blokirajuća sila sa svake strane, kapacitet po keramičkoj strani, maksimalni napon za rad.


U tablici 2.1 navedeni su podaci za 4 različita piezoelektrična grednih pretvornika tvrtke Johnson Matthey ([www.piezoproducts.com](http://www.piezoproducts.com)). Geometrijske značajke kotirane su na slici 3.1.

Pretvornik	1	2	3	4
materijal	M1100	M1100	M1876	M1876
ukupna duljina $l_b$ [mm]	49.95	49.0	47.0	32.5
slobodna duljina $l$ [mm]	38.0	38.0	38.0	27.5
širina $w$ [mm]	7.2	2.1	5.9	1.9
debljina $t$ [mm]	0.80	0.90	0.80	0.70
ukupni otklon $y$ [mm]	2	2	2.8	1.4
sila na pojedinoj strani $F_b$ [mN]	450	150	500	180
kapacitet pojedine keramičke strane $C$ [nF]	45	14	60	10
radni napon $U_{max}$ [V]	230	230	230	230

Tablica 2.1: Parametri pretvornika

Izložen promjenjivom električnom polju, piezoelektrični pretvornik se deformira periodično, frekvencijom polja. Na slici 2.9 prikazan je graf koji pokazuje odnos električne vodljivosti (*eng. admittance*) i frekvencije. Povećavanjem iznosa frekvencije, dostiže se frekvencija minimalne impedancije (maksimalne električne vodljivosti),  $f_m$ , koja aproksimira frekvenciju serijske rezonance,  $f_s$ . Kod frekvencije serijske rezonance impedancija električnog dijela ekvivalentnog kruga je nula, što znači da su samo mehanički parametri relevantni za karakteristike pretvornika. Frekvencija minimalne impedancije je rezonantna frekvencija,  $f_r$ , frekvencija na kojoj pretvornik vibrira najbrže te najučinkovitije pretvara električnu energiju u mehaničku.

Kako se frekvencija nadalje povećava, impedancija raste do maksimuma (minimalna električna vodljivost). Frekvencija maksimalne impedancije,  $f_n$ , aproksimira frekvenciju paralelne rezonance,  $f_p$ , frekvenciju kod koje je paralelni otpor ekvivalentnog električnog kruga beskonačan, ako se zanemari otpor uzrokovan mehaničkim gubicima. Frekvencija maksimalne impedancije je antirezonantna frekvencija  $f_a$ .

Slika 2.9: Provodnost (*eng. admittance*) pretvornika kod karakterističnih frekvencija




### 3 Eksperiment

#### 3.1 Uvod i oprema

Iako podijeljen na nekoliko dijelova, u osnovi, eksperiment se bazira na napajanju jednog piezokeramičkog sloja pretvornika, koristeći ga kao aktuator te mjerenja napona i struje s drugog sloja piezokeramike koji služi kao senzor. Također, mjeri se postignuta brzina i otklon. Pokusi i mjerenja traju dok se ne primjeti promjena parametara pretvornika, odnosno dok ne dođe do zastoja u radu, kvara. Parametri se mjere u određenim intervalima, otprilike svakih sat vremena.

U eksperimentu je korištena sljedeća oprema:

- piezoelektrični bimorfni pretvornik, slika 3.4, 10 - parametri navedeni u tablici 3.1, na osnovi geometrijskih značajki prikazanih na slici 3.1,



Slika 3.1: Piezoelektrični pretvornik, geometrijske značajke


materijal	M1876
ukupna duljina $l_b$ [mm]	49.95
slobodna duljina $l$ [mm]	38.0
širina $w$ [mm]	2.1
debljina $t$ [mm]	0.9
debljina piezosloja $t_p$ [mm]	0.31
debljina međusloja $t_{sh}$ [mm]	0.28

Tablica 3.1: Parametri eksperimentalnog pretvornika

- hvataljka, slika 3.4, 9
- generator signala, slika 3.2, 3
- pojačalo, slika 3.2, 4
- diferencijalna sonda (*eng. differential probe*), slika 3.3, 7
- osciloskop, slika 3.2, 2

- mjerač struje (*eng. current probe*), slika 3.3, 6
- laserski vibrometar:
  - laserska glava, slika 3.4, 11
  - upravljački uređaj (*eng. vibrometer controller*), slika 3.2, 1
  - interferometar optičkog vlakna (*eng. fiber interferometer*), slika 3.3, 8
- mjerač impedancije (*eng. impedance analyser*), slika 3.3, 5


Fotografije opreme i eksperimenta:



Slika 3.2: Oprema



Slika 3.3: Oprema



Slika 3.4: Eksperiment

## 3.2 Eksperiment 1


### 3.2.1 Provedba eksperimenta 1

Jedna strana pretvornika, gornja, bila je napajana sinusnim signalom frekvencije 180 Hz, istosmjerne komponente 78 V, amplitude 75 V. Na osciloskopu su mjereni sljedeći parametri: ulazni napon aktuatorne strane, izlazni napon senzorske strane i brzina mjerena laserskim vibrometrom. Ulazni signal oblika sinusa, amplitude 3.5 V generiran je na signal generatoru (slika 3.2, 3) te pojačan preko pojačala (slika 3.2, 4) na iznos od 78 V DC komponente te 75 V ukupne amplitude. U osciloskop dovedena su 4 signala: ulazni napon direktno iz pojačala, zatim ulazni napon mjereno, odnosno spojen direktno na gornju elektrodu i međusloj, zatim izlazni napon očitano s donje elektrode i međusloja preko diferencijalne sonde (slika 3.3) te brzina mjerena laserskim vibrometrom. Laserski vibrometar sastoji se od lasera s dvije glave, ali je u ovom eksperimentu korištena samo jedna glava (slika 3.4, 11), upravljačkog uređaja (*eng. vibrometer controller*) (slika 3.2, 1) te interferometra optičkog vlakna (*eng. fiber interferometer*), (slika 3.3, 8). Pretvornik se napajao i podaci su se uzorkovali sve dok se nije bila primijećena značajna promjena brzine, odnosno pomaka (otklona) i izlaznog napona senzorske strane. Napajanje pretvornika u ovom eksperimentu trajalo je 12 sati. Podatci s osciloskopa *Yokogawa DL1640L* preko mreže prebačeni su na računalo u binarnom obliku s .wvf i .hdr ekstenzijama, za čije čitanje je potrebna skripta softvera Matlab dostupna na [www.mathworks.com](http://www.mathworks.com) (datoteka *wvfread\_V1.7*).

### 3.2.2 Analiza eksperimenta 1


Uzorkovanje je provedeno svakih sat vremena tijekom eksperimenta. Nakon obrade signala u programskom paketu MATLAB, kod je priložen na kraju potpoglavlja, slijedi analiza mjerenih rezultata.

Na slici 3.5 prikazan je signal izlaznog napona senzorske strane sniman u prvom satu eksperimenta. Broj uzoraka u jednom snimanju ovisi o rezoluciji postavljenoj na osciloskopu, u ovom eksperimentu jedno snimanje ima 100200 uzoraka. Nakon oduzimanja srednje vrijednosti, odnosno oduzimanja DC razine narinute na pojačalu, vidljiva je sinusna karakteristika senzorskog signala.




Slika 3.5: Napon na senzorskoj strani - jedno uzorkovanje

Kako je eksperiment trajao 12 sati, snimano je 12 datoteka, što sveukupno rezultira s 1202400 uzoraka, pokazanih na slici 3.6. Vidljivo je postepeno smanjenje amplitudnih vrijednosti signala, čiji iznosi su vidljivi na slici 3.7.




Slika 3.6: Napon na senzorskoj strani kroz 12 sati




Slika 3.7: Promjena amplitudnih vrijednosti senzorskog napona svih uzoraka

Korištenjem laserskog vibrometra moguće je direktno mjerenje pozicije, tj. odklona, ali se to pokazalo vrlo nestabilnim uslijed visoke frekvencije vibriranja. Praktičnije je mjerenje brzine te naknadno integriranje obradom u programskom paketu MATLAB. Na slici 3.8, na gornjem grafu vidljiva je mjerena brzina jednog uzorkovanja, dok je na donjem vidljiv pomak dobiven integriranjem brzine.




Slika 3.8: Mjerena brzina i pomak jednog uzorkovanja

Slika 3.9 prikazuje promjenu pomaka tokom cijelog eksperimenta, kroz svih 12 snimaka, odnosno 1202400 uzoraka.



Slika 3.9: Pomak pretvornika kroz 12 sati

Na slici 3.10 vidljiva je promjena amplitudnih vrijednosti kroz uzorke uzorkovane tokom 12 sati.



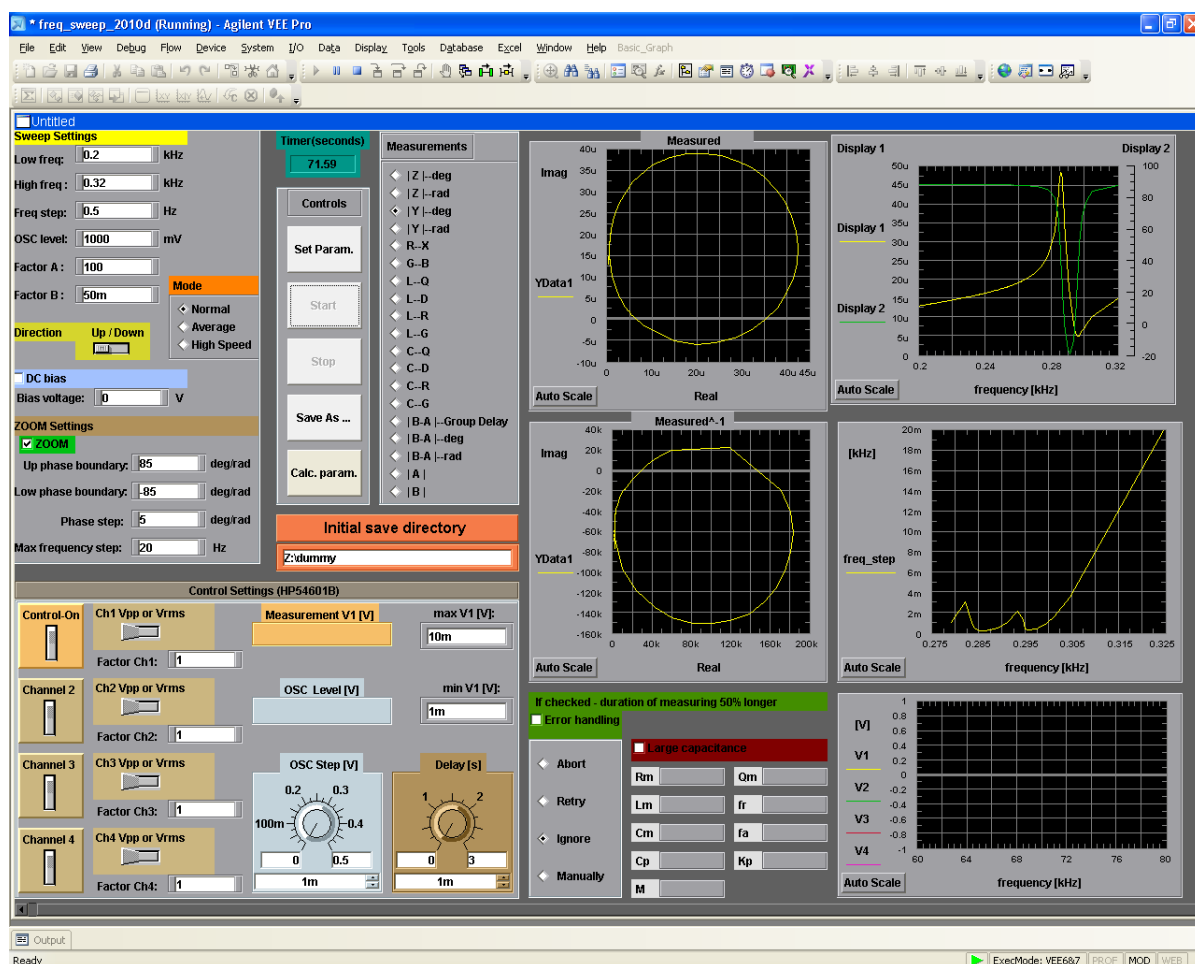
Slika 3.10: Promjena amplitudnih vrijednosti pomaka kroz 12 sati

Vrijednost dvostruke amplitude napona na senzorskoj strani piezokeramičkog sloja pretvornika na početku eksperimenta iznosi 13.333 V, dok je na kraju eksperimenta 8.333 V. Iznos dvostruke amplitude pomaka vrha pretvornika je 0.88644 mm, dok na kraju eksperimenta iznosi 0.50817 mm. Smatra se da je u piezoelektričnom bimorfnom pretvorniku došlo do zamora materijala ili loma, odnosno da je komponentu potrebno zamijeniti, kada vrijednosti pomaka padnu ispod 80% početnih vrijednosti. U ovom eksperimentu pomak se nakon 12 radnih sati reducirao na 57.33%, dok je napon na senzorskoj strani reducirao na 62.5% početne vrijednosti, iz čega se može zaključiti da je došlo do zamora piezoelektričnog materijala.

### 3.3 Eksperiment 2

#### 3.3.1 Provedba eksperimenta 2

U ovom eksperimentu pretvornik je također napajan sinusnim naponom od 150 V dvos-truke amplitude, 78 V istosmjerne komponente te frekvencije 100 Hz. Uz mjerenje senzorskog napona i pomaka, svakih sat vremena mjere se i dodatni parametri preko mjerača impedancije (*eng. impedance analyser*, slika 3.3, 5). Softverom kreiranim na Uni Paderbornu od struč-njaka na Strojarskom fakultetu, odjelu za Mehatroniku i dinamiku, koji služi za analizu para-metara piezoelektričnih elemenara preko impedancije pretvornika, programiranim u grafičkom softverskom paketu Agilent VEE Pro, moguće je dobiti vrijednosti parametara specifičnih za piezoelektrične elemente. Na slici 3.11 vidljiv je prikaz softvera (*freq\_sweep*) za analizu impe-dancije.




Slika 3.11: Analiza električne vodljivosti (*admittance*) pretvornika

Nakon spajanja pretvornika na mjerač impedancije, prije pokretanja softvera podešava se raspon frekvencije za ispitivanje, najčešće od 0.2 do 0.32 kHz. Raspon vrijednosti rezonantne i antirezonantne frekvencije pretvornika dan je od proizvođača, ali iznos nije dovoljno točan,

stoga je potrebno provesti analizu. Analizom se u gornjem desnom kutu na slici 3.11 iscrtavaju grafovi frekvencije i faznog pomaka. Nakon provedenog mjerenja, podaci se očitavaju i analiziraju korištenjem ranije spomenute datoteke te se dobiva graf električne vodljivosti (impedancije<sup>-1</sup>), prikazan na slici 3.12. Analizom električne vodljivosti dobivaju se sljedeći parametri:

- ekvivalentni otpor koji predstavlja prigušenje konstrukcije,  $R_m$   $\Omega$
- ekvivalentni induktivitet koji predstavlja masu konstrukcije,  $L_m$  mH
- ekvivalentni kapacitet koji predstavlja krutost konstrukcije,  $C_m$  pF
- kapacitet piezoelektričnog sustava  $C_p$  nF
- rezonantna frekvencija,  $f_r$  Hz
- antirezonantna frekvencija,  $f_a$  Hz
- frekvencija maksimalne vodljivosti,  $f_m$  Hz
- frekvencija minimalne vodljivosti,  $f_n$  Hz
- frekvencija serijske rezonance,  $f_s$  Hz



Slika 3.12: Električna vodljivost (*eng. admittance*) pretvornika s parametrima




Pomoću mjerača impedancije moguće je povezati promjenu jednog od najznačajnijih parametara, rezonantne frekvencije pretvornika, s promjenom iznosa napona senzorske strane pretvornika i mjerenim pomakom. Eksperiment je trajao 30 sati zbog manje frekvencije ulaznog signala, svakih sat vremena uzorkovani su mjereni signali na osciloskopu i izvršena je analiza impedancije gorenjg sloja piezokeramike koji je služio kao aktuator.


### 3.3.2 Analiza eksperimenta 2

Osim zamora i trošenja materijala, moguć oblik kvara je i lom osjetljive piezokeramike, ili odvajanje sloja piezokeramike od međusloja. Tim pojavama pretvornik također gubi svoja svojstva, stoga ih je potrebno detektirati i poduzeti odgovarajuće mjere.

Kako dolazi do zamora ili trošenja materijala, postepeno dolazi i do smanjenja iznosa rezonantne frekvencije. Kada je pretvornik u kvaru, rezonantna frekvencija se smanji za 40ak Hz. Prvo mjerenje pokazalo je iznos frekvencije od 251.22 Hz te je kroz 29 sati eksperimenta frekvencija postepeno smanjena na iznos od 241.53 Hz, što je još uvijek premalo smanjenje da bi se moglo reći da je pretvornik u kvaru. U zadnjem mjerenju eksperimenta vidljivo je naglo smanjenje iznosa rezonantne frekvencije na 214.87 Hz (slika 3.13), na temelju čega proizlazi zaključak da je došlo do loma u piezokeramici pretvornika.




Slika 3.13: Promjena rezonantne frekvencije kroz mjerenja



Slika 3.14: Promjena ekvivalentnog otpora kroz mjerenja

Također, na parametru ekvivalentnog otpora  $R_m$  vidljivo je da je došlo do nagle promjene, odnosno loma, naglim skokom između 28. i 29. mjerenja (slika 3.14).

Na slici 3.15 vidljiva je usporedba električne vodljivosti i iznosa odgovarajućih parametara prije i nakon loma.




Slika 3.15: Mjerena električna vodljivost pretvornika prije i nakon loma (crno - prije, crveno - poslije)

### 3.4 Eksperiment 3

#### 3.4.1 Provedba eksperimenta 3


Eksperiment 3 proveden je s pretvornikom nešto drugačijih parametara, materijala M1100 i nešto manje širine, 1.9 mm. Ovaj pretvornik veće je kvalitete, tako da je njegovo testiranje dok nije došlo do potpunog kvara trajalo čak 60 sati, iako je narinut napon kvadratne karakteristike, za razliku od prijašnjih sinusnih. Razlog korištenja kvadratnog signala umjesto sinusnog su oštri rubovi signala koji uzrokuju brže trošenje i zamor materijala. Testiran je na 100 Hz, 150 V dvostruke amplitude, 78 V istosmjerne komponente kvadratnog signala te su također mjereni

parametri na mjerачu impedancije svakih sat vremena. Na slici 3.16 prikazan je ulazni signal mjerен osciloskopom.



Slika 3.16: Ulazni signal mjerен osciloskopom

Na slici 3.17 prikazana je fotografija eksperimenta na kojoj je vidljiv pomak vrha pretvornika mjerен laserskim vibrometrom te je jasno vidljiva hvataljka preko koje su na vodiče spojeni gornji i donji sloj piezokeramike.



Slika 3.17: Pretvornik

### 3.4.2 Analiza eksperimenta 3

Kako je u ovom eksperimentu korišten kvadratni signal, potrebno je, uz analizu amplitudnih vrijednosti, analizirati dodatne značajke karakteristične za analizu signala. Analiziranjem izlaznog, senzorskog napona potrebno je naći značajke koje također pokazuju rastuću ili pada-

juću tendenciju kako dolazi do zamora materijala.

Analizirane su sljedeće značajke izlaznog, senzorskog napona kroz 59 uzorkovanja, prikazane na slici 3.18:

- maksimum (*max*)
- efektivna vrijednost (*RMS*)

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}$$

- varijanca

$$VAR = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

- vršni faktor (*crest factor*)


$$CF = \frac{max}{RMS}$$

- faktor jasnoće (*clearance factor*)

$$CLF = \frac{max}{(\frac{1}{n} \sum_{i=1}^n \sqrt{|x|})^2}$$

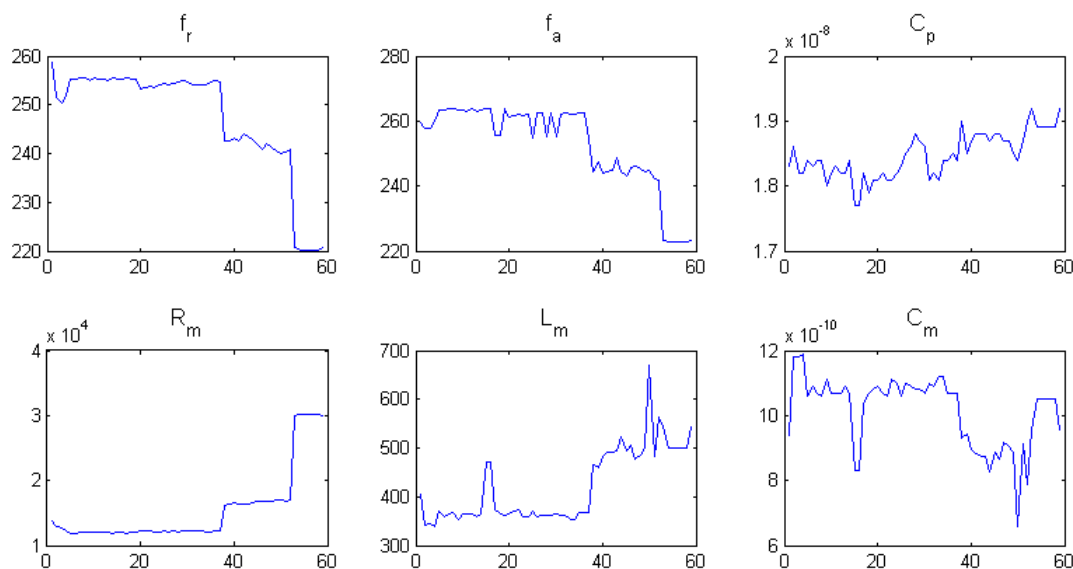
- faktor oblika (*shape factor*)

$$SF = \frac{RMS}{\frac{1}{n} \sum_{i=1}^n |x_i|}$$



Slika 3.18: Analiza signala senzorskog napona

Na temelju grafova koji se nalaze na slici 3.18, vidljivo je da sve značajke osim vršnog faktora pokazuju neki oblik rasta ili pada amplitude, te ih se može koristiti u nastavku.



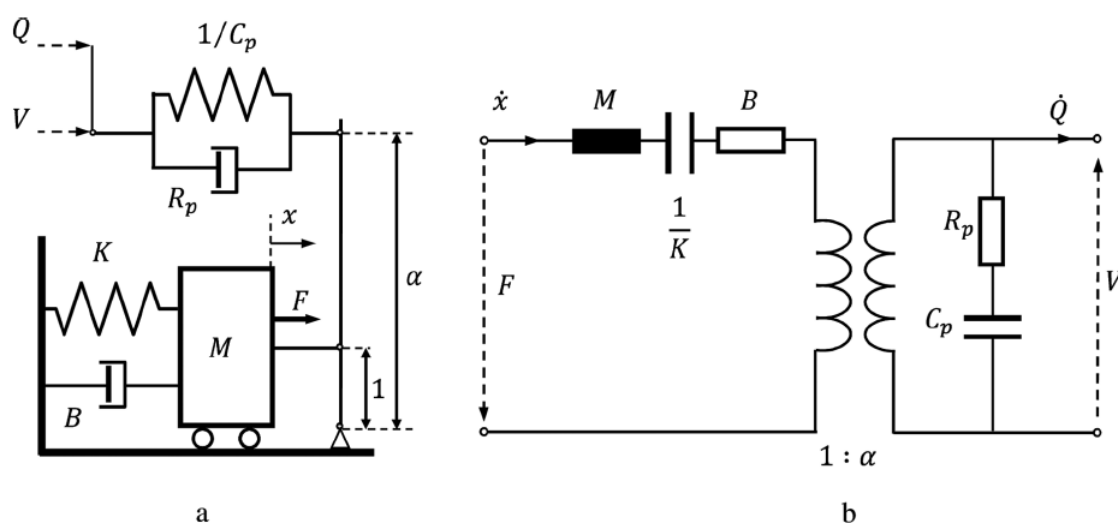
Slika 3.19: Analiza parametara dobivenih analizom električne vodljivosti

Na slici 3.19 prikazani su parametri dobiveni mjerачem impedancije gornje strane piezokeramike pretvornika. Također, potrebno je uočiti koji parametri pokazuju rast ili pad usporedno sa zamorom materijala. Vidljivo je da rast ili pad pokazuju sljedeći parametri: rezonantna frekvencija  $f_r$ , antirezonantna frekvencija  $f_a$ , ekvivalentni kapacitet  $C_p$  te ekvivalentni otpor  $R_m$  te će ih se stoga moći koristiti u primjeni neuronskih mreža.

## 4 Izgradnja i verifikacija matematičkog modela piezoelektričnog pretvornika

### 4.1 Matematički model pretvornika

Piezoelektrični materijali su elektromehanički materijali koji posjeduju spoj mehaničkih i električnih karakteristika. Slika 4.1 prikazuje ekvivalentan mehanički (a) i električni (b) model koji opisuju elektromehaničko ponašanje piezoelektričnog elementa blizu njegove rezonantne frekvencije.



Slika 4.1: Ekvivalentni model u a) mehaničkom i b) električnom prikazu

Mehanički parametri modela su ekvivalentna masa  $M$ , ekvivalentno mehaničko prigušenje  $B$  i ekvivalentna mehanička krutost  $K$ . Parametri koji opisuju električna svojstva su kapacitet  $C_p$  i otpor  $R_p$ .  $\alpha$  je prijednosni faktor između električne i mehaničke domene.  $V$  je generiran ili narinut napon,  $Q$  električni naboj,  $F$  je generirana ili narinuta sila te  $x$  pomak mase  $M$ .

Na temelju mehaničkog prikaza sustava dobivena je sljedeća diferencijalna jednadžba:

$$M\ddot{x}(t) + B\dot{x}(t) + Kx(t) = F(t) \quad (4.1)$$

gdje je:

$x$  - pomak, [m]

$F$  - sila, [N]

$M$  - ekvivalentna masa, [kg]

$B$  - ekvivalentno mehaničko prigušenje, [Ns/m]

$K$  - ekvivalentna mehanička krutost, [N/m]

Odnos između mehaničkog i električnog dijela pretvornika prikazan je preko prijenosnog faktora  $\alpha$ . Iz mehaničkog prikaza dobivena je sljedeća relacija, momentna jednadžba oko točke A:

$$F(t) \cdot 1 = V(t) \cdot \alpha$$

$$F(t) = \alpha V(t) \quad (4.2)$$

Iz električnog prikaza piezoelementa proizlaze sljedeće jednadžbe:

$$\alpha \dot{x}(t) = C_p \dot{v}(t) + \dot{q}(t) \quad (4.3)$$

$$\dot{q}(t) = \frac{v(t)}{R} \quad (4.4)$$

$$\dot{x} = \alpha \dot{q}$$

$$x = \alpha q \quad (4.5)$$

Primjena Laplaceove transformacije na jednadžbe (4.1), (4.3) i (4.4):

$$[Ms^2 + Bs + K]X(s) = F(s) \quad (4.6)$$

$$\alpha X(s) = C_p V(s) + Q(s) \quad (4.7)$$

$$sQ(s) = \frac{V(s)}{R} \quad (4.8)$$

Za aktuatorsku stranu pretvornika ulazna varijabla je napon  $V(s)$ , dok je izlazna varijabla pomak  $X(s)$ . Stoga slijedi prijenosna funkcija aktuatorske strane iz (4.6):

$$\frac{X(s)}{V(s)} = \frac{\alpha}{Ms^2 + Bs + K} \quad (4.9)$$

Kod senzorske strane pretvornika, ulazna varijabla je pomak  $X(s)$ , dok je izlazna varijabla napon  $V(s)$ . Iz (4.7) i (4.8) slijedi prijenosna funkcija:

$$\frac{V(s)}{X(s)} = \frac{\alpha R s}{RC_p s + 1} \quad (4.10)$$

## 4.2 Izračun ekvivalentnih parametara modela

Za verificiranje modela potreban je izračun ekvivalentnih parametara. Izračun je baziran prema [4].

Kod analiziranja krutosti, dvije granice krutosti mogu biti definirane kod piezoelektričnih grednih pretvornika: gornja i donja. Kod gornje granice krutosti elektrode su otvorene, nema protoka naboja,  $Q = 0$  te je odnos između sile i pomaka definiran sljedećom jednačinom:

$$F = \left( K + \frac{\alpha^2}{C_p} \right) x \quad (4.11)$$

Ako su elektrode kratko spojene, postoji protok naboja te vrijedi  $V = 0$ , što označava donju granicu krutosti. U tom slučaju odnos između sile i pomaka definiran je jednačinom:

$$F = Kx \quad (4.12)$$

Za pretvornike nad kojima su provedeni eksperimenti vrijedi donja granica krutosti, odnos sile i pomaka definiran je jednačinom (4.12), ali je potrebno razmatrati i gornju granicu krutosti kako bi se dobile odgovarajuće vrijednosti traženih parametara.

Važan parametar za izračun krutosti je neotpornosti (*eng. compliance*)  $s$ , za gornju granicu  $s^D$  te donju  $s^E$ . Odnos između gornje i donje neotpornosti:

$$s^D = s^E (1 - k^2) \quad (4.13)$$

gdje je:

$k$  - piezoelektrični faktor spoja (*eng. coupling factor*)

Piezoelektrični pretvornici rade na dva načina:

- 33. način
- 31. način

U 33. modu (načinu), smjer narinutog ili izvršenog (*eng. exerted*) naprezanja i deformacije te smjer narinutog ili dobivenog napona su isti kao i smjer polaziracije. U 31. načinu, smjer narinutog ili dobivenog napona je isti kao i smjer polarizacije, dok su deformacija i naprezanje okomiti na smjer polarizacije. Za izračun koji slijedi, u obzir je uzet 31. način.

Za daljnji izračun parametara potrebno je u obzir uzeti geometrijske značajke bazirane na slici 3.1, čije vrijednosti su definirane u tablici 3.1.



Izraz za krutost gredne konstrukcije:

$$K_b = \frac{3Y_b I_b}{l^3} \quad (4.14)$$

vlastita frekvencija:

$$f_b = \frac{1}{2\pi} \sqrt{\frac{K_b}{M}} \quad (4.15)$$

gdje je:

$Y_b$  - modul elastičnosti, [N/m<sup>2</sup>]

$I_b$  - moment inercije grede, [m<sup>4</sup>]

Modul elastičnosti donje granice krutosti ( $Y_{psc}$ ):

$$Y_{psc} = \frac{1}{sE} \quad (4.16)$$

Modul elastičnosti gornje granice krutosti ( $Y_{poc}$ ):

$$Y_{poc} = \frac{1}{sD} = \frac{1}{sE(1-k^2)} \quad (4.17)$$

Izraz za modul elastičnosti piezoelektričnog elementa gredne konstrukcije sa slojevima iste širine:

$$Y_b = \frac{2t_p Y_p + t_{sh} Y_{sh}}{2t_p + t_{sh}} \quad (4.18)$$

gdje je:

$Y_p$  - modul elastičnosti piezokeramičkog sloja, [N/m<sup>2</sup>]

$Y_{sh}$  - modul elastičnosti međusloja, [N/m<sup>2</sup>]

Modul elastičnosti bimorfnog pretvornika kod donje granice krutosti ( $Y_{bsc}$ ):

$$Y_{bsc} = \frac{2t_p + t_{sh} Y_{sh} s^E}{s^E (2t_p + t_{sh})} \quad (4.19)$$

Modul elastičnosti bimorfnog pretvornika kod gornje granice krutosti ( $Y_{boc}$ ):

$$Y_{boc} = \frac{2t_p + t_{sh} Y_{sh} s^E (1-k^2)}{s^E (1-k^2) (2t_p + t_{sh})} \quad (4.20)$$

Moment inercije pretvornika za donju granicu krutosti ( $I_{bsc}$ ) je:

$$I_{bsc} = \frac{Y_{psc}}{Y_{sh}} \frac{wt_p^3}{6} \left[ 1 + 3 \left( 1 + \frac{t_{sh}}{t_p} \right)^2 \right] + \frac{wt_{sh}^3}{12} \quad (4.21)$$

Moment inercije pretvornika za gornju granicu krutosti ( $I_{boc}$ ) je:

$$I_{boc} = \frac{Y_{poc}}{Y_{sh}} \frac{wt_p^3}{6} \left[ 1 + 3 \left( 1 + \frac{t_{sh}}{t_p} \right)^2 \right] + \frac{wt_{sh}^3}{12} \quad (4.22)$$

Slijedi izraz za donju granicu krutosti prema (4.14):

$$K_{bsc} = \frac{3Y_{bsc}I_{bsc}}{l^3} \quad (4.23)$$

te gornju granicu krutosti:

$$K_{boc} = \frac{3Y_{boc}I_{boc}}{l^3} \quad (4.24)$$

Izraz za ekvivalentnu masu korištenu za izračunavanje vlastite frekvencije grede:

$$M = \frac{33}{140} M_b + M_t; M_t = 0 \quad (4.25)$$

$$M_b = (2\rho_p t_p + \rho_s h t_s h) w l \quad (4.26)$$

gdje je:

$M_b$  - masa pretvornika, [kg]

$\rho_p$  - gustoća piezokeramičkog sloja, [kg/m<sup>3</sup>]

$\rho_{sh}$  - gustoća međusloja, [kg/m<sup>3</sup>]

Izraz za donju granicu vlastite frekvencije  $f_{bsc}$ :

$$f_{bsc} = \frac{1}{2\pi} \sqrt{\frac{K_{bsc}}{M}} \quad (4.27)$$

Izraz za gornju granicu vlastite frekvencije  $f_{boc}$ :

$$f_{boc} = \frac{1}{2\pi} \sqrt{\frac{K_{boc}}{M}} \quad (4.28)$$

Kapacitet jednog piezoelektričnog sloja:

$$C_{p,1} = \frac{wl_b \epsilon_3 3^T (1 - k_{31}^2)}{t_p} \quad (4.29)$$

gdje je:

$\epsilon_{33}^T$  - piezoelektrična relativna dielektrična konstanta, [nF/m]

$k_{31}$  - piezoelektrični faktor spoja (*eng. coupling factor*)

Prijenosni faktor:

$$\alpha = \sqrt{(K_{boc} - K_{bsc}) C_p} \quad (4.30)$$

U tablici 3.1 navedene su geometrijske značajke pretvornika, u tablici 4.2 navedene su vrijednosti parametara dobivene od proizvođača za materijal M1876, dok su u tablici 4.2 vrijednosti izračunate izračunate vrijednosti parametara izraženih jednadžbama (4.13) - (4.30).

parametar	jedinica	iznos
$\rho_p$	kg/m <sup>3</sup>	8100
$\rho_{sh}$	kg/m <sup>3</sup>	1800
$\rho_{sh}$	kg/m <sup>3</sup>	1800
$s_{11}^E$	m <sup>2</sup> /N	$14.2 \cdot 10^{-12}$
$k_{31}$	/	0.33
$\epsilon_{33}^T$	nF/m	45
$Y_{sh}$	N/m <sup>2</sup>	$120 \cdot 10^9$

Tablica 4.1: Veličine dobivene od proizvođača za materijal M1876

parametar	jedinica	iznos
$Y_{psc}$	N/m <sup>2</sup>	$7.0423 \cdot 10^{10}$
$Y_{poc}$	N/m <sup>2</sup>	$7.9029 \cdot 10^{10}$
$Y_{bsc}$	N/m <sup>2</sup>	$8.5847 \cdot 10^{10}$
$Y_{boc}$	N/m <sup>2</sup>	$9.1775 \cdot 10^{10}$
$I_{bsc}$	m <sup>4</sup>	$7.6455 \cdot 10^{-14}$
$I_{boc}$	m <sup>4</sup>	$8.5329 \cdot 10^{-14}$
$K_{bsc}$	N/m	358.8395
$K_{boc}$	N/m	428.1478
$M$	kg	$1.0394 \cdot 10^{-4}$
$f_s$	Hz	295.71
$f_p$	Hz	323.01
$C_p$	nF	1.3446
$\alpha$	/	9.6537
$f_o$	Hz	100
$d.rat.$	/	0.3382
$Cc$	Ns/m	0.3863
$B$	Ns/m	0.1306
$R$	$\Omega$	20000
$f_{sim}$	V	100
$t_{sim}$	V	0.2004

Tablica 4.2: Parametri pretvornika dobiveni na temelju (4.13) - (4.30)

gdje je:

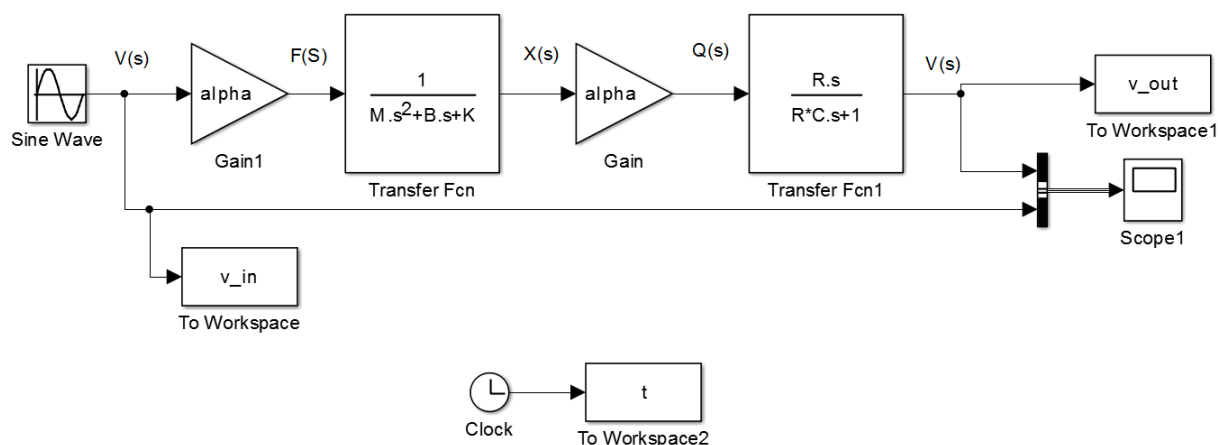
$Cc$  - koeficijent kritičnog prigušenja, Ns/m

$k_{31}$  - piezoelektrični faktor spoja (*eng.coupling factor*)


### 4.3 Verifikacija matematičkog modela

Verifikacija matematičkog modela piezoelektričnog bimorfnog pretvornika realizirana je u matematičkom programskom paketu MATLAB, softveru za modeliranje, simulaciju i ana-

lizu dinamičkih sustava SIMULINK. Na slici 4.2 prikazan je konstruiran model pretvornika, temeljen na prijenosnim funkcijama (4.9) i (4.10).



Slika 4.2: SIMULINK model piezoelektričnog pretvornika



Slika 4.3: Usporedba mjenog i simuliranog signala


Na slici 4.3 prikazana je usporedba mjenog i simuliranog signala sinusnog ulaznog napona amplitude 75V, 100 Hz te mjenog i simuliranog senzorskog, izlaznog napona. Mjereni i simulirani podaci se poklapaju, čime je potvrđena točnost matematičkog modela pretvornika.

## 5 Primjena statičkih neuronskih mreža u praćenju degradacije pretvornika

### 5.1 Uvod u umjetne neuronske mreže


#### 5.1.1 Biološki i umjetni neuron

Osnovni koncept umjetnih neuronskih mreža bazira se na neuronskoj mreži mozga čovjeka. Biološki neuron (slika 5.1) sastoji se od tijela, aksona, dendrita i sinapsi. Akson se može zamisliti kao tanka cjevčica koja je jednim krajem spojena na tijelo neurona, dok se drugi kraj dijeli na niz grana. Krajevi niza grana dodiruju dendrite ili tijelo drugog neurona. Mali razmak između završetka aksona prethodnog neurona i dendrita ili tijela sljedećeg neurona naziva se sinapsa. Impulsi jednog neurona preko aksona dolaze do sinapsi, gdje se signali različitog inteziteta šalju kroz dendrite u tijelo drugog neurona, ili direktno na tijelo neurona, ukoliko je akson sinapsom spojen direktno na tijelo. Da bi neuron "ispalio" impuls u akson, njegova uzbuda mora biti veća od praga osjetljivosti neurona.



Slika 5.1: Pojednostavljena struktura biološkog neurona

Umjetni neuron (slika 5.2) oponaša osnovne funkcije biološkog neurona. Ulazi umjetnog neurona zamjenjuju aksonne prethodnih bioloških neurona (veza s okolinom), težine zamjenjuju sinapse dok ulazi u sumator zamjenjuju dendrite. Težine, kao i sinapse, povezuju izlaze drugih neurona (aksoni) s ulazima sumatora (dendriti). Tijelo neurona zamjenjuje se sumatorom, dok aktivacijska funkcija preuzima ulogu praga osjetljivosti biološkog neurona. Izlaz iz sumatora predstavlja akson. Svaki neuron ima jedan ili više ulaza, ali samo jedan izlaz.



Slika 5.2: Struktura umjetnog neurona

Aktivacijske funkcije mogu biti linearne i nelinearne. Linearne množe izlaz iz sumatora nekim faktorom te se tako dobiva izlaz iz neurona. Nelinearne aktivacijske funkcije prevode izlaz iz sumatora na izlaz neurona preko nelinearnog pojačanja. Najčešće nelinearne funkcije su funkcije praga osjetljivosti, sigmoidalne, hiperboličke i harmoničke.

### 5.1.2 Osnovne podjele umjetnih neuronskih mreža

Umjetne neuronske mreže kreirane su povezivanjem umjetnih neurona prema određenoj topologiji. Paralelno složen skup neurona gradi jedan sloj neuronske mreže. Dakle, prema broju slojeva mreže mogu biti:

- **jednoslojne**,
- **višeslojne** - sastoje se od ulaznog i izlaznog sloja, a između njih je jedan ili više sakrivenih slojeva.

Uz broj slojeva, osnovna podjela mreža je također prema toku signala odnosno strukturi neurona u mreži, gdje se mreža dijeli na:

- **statičke** (unaprijedne) - slojevi neuronske mreže povezani su tako da signali putuju samo u jednom smjeru, od ulaza prema izlazu. Statički neuron ne sadrži dinamičke članove pa stoga njegov izlaz ovisi samo o trenutačnim vrijednostima ulaznih signala i težinskim koeficijentima.

- **dinamičke** (povratne) - Kod ovog modela neurona prostiranje signala odvija se unaprijed, ali i unatrag preko unutarnjih povratnih veza. Dinamika se dodaje ispred aktivacijske funkcije, tako da aktivnost neurona bude u funkciji stanja neurona. Dinamički neuron djeluje na temelju ulaznih signala i prethodno dobivenih vrijednosti izlazne veličine dinamičkog člana dinamičkog neurona.

Neuronske mreže kategoriziraju se i prema pravilu, odnosno algoritmu učenja koji služi za podešavanje parametara mreže s ciljem postizanja željenog vladanja. Nabrojeno je samo nekoliko od mnogobrojnih algoritama učenja.

- učenje korekcijom pogreške:
  - Back propagation,
  - Gauss Newton,
  - Levenberg Marquardt.
- Hebbovo učenje, optimalno učenje, adaptivno, statističko, ...

Prema učenju neuronskih mreža, razlikuje se **supervizorno** (uz nadzor) i **nesupervizorno** (bez nadzora) učenje. Supervizorno učenje provodi "učitelj" neuronske mreže, koji promatra i korigira ponašanje mreže. Nesupervizorno učenje bazira se na samoorganizirajućim mrežama. Prema načinu učenja postoji učenje kroz **jedan korak** ili **iterativno**. Jedan korak predstavlja prolazak kroz cijeli skup ulaznih i izlaznih parametara. Također, prema podacima za učenje mreže mogu biti **autoasocijativne** i **heteroasocijativne**.

U nastavku se detaljnije opisuje i koristi statička višeslojna mreža, učena povratnim prostiranjem pogreške uz nadzor (učitelja).

## 5.2 Statička neuronska mreža

Model statičkog neurona prikazan je na slici 5.2. Za svaki statički neuron karakteristične su sljedeće značajke:

- da svaki statički neuron ima više ulaza i samo jedan izlaz,
- da je svakom statičkom neuronu dodan ulaz vrijednosti 1 (*bias*).

*Bias* ima funkciju određivanja oblika, nagiba i orijentacije sigmoidalne aktivacijske funkcije. Korištenjem biasa moguće je aktivacijsku funkciju translatirati za određeni iznos duž x-osi, u suprotnom je moguće samo mijenjati iznos nagiba.


Temeljne podfunkcije statičkog neurona su funkcija sume (5.1) i aktivacijska funkcija (5.2).

$$net = \sum_{j=1}^J w_j x_j \quad (5.1)$$

$$y = \gamma(\text{net}) \quad (5.2)$$

Najčešće korištena aktivacijska funkcija, korištena i u primjerima u idućem potpoglavlju, je nelinearna bipolarna sigmoidalna funkcija, (5.3), slika 5.3. Izlazi ove funkcije normiraju vrijednosti izlaza između -1 i 1, stoga je potrebno ulaze i izlaze normirati prije učenja mreže.

$$y = \frac{2}{1 + e^{-\text{net}}} - 1 \quad (5.3)$$



Slika 5.3: Nelinearna bipolarna sigmoidalna aktivacijska funkcija

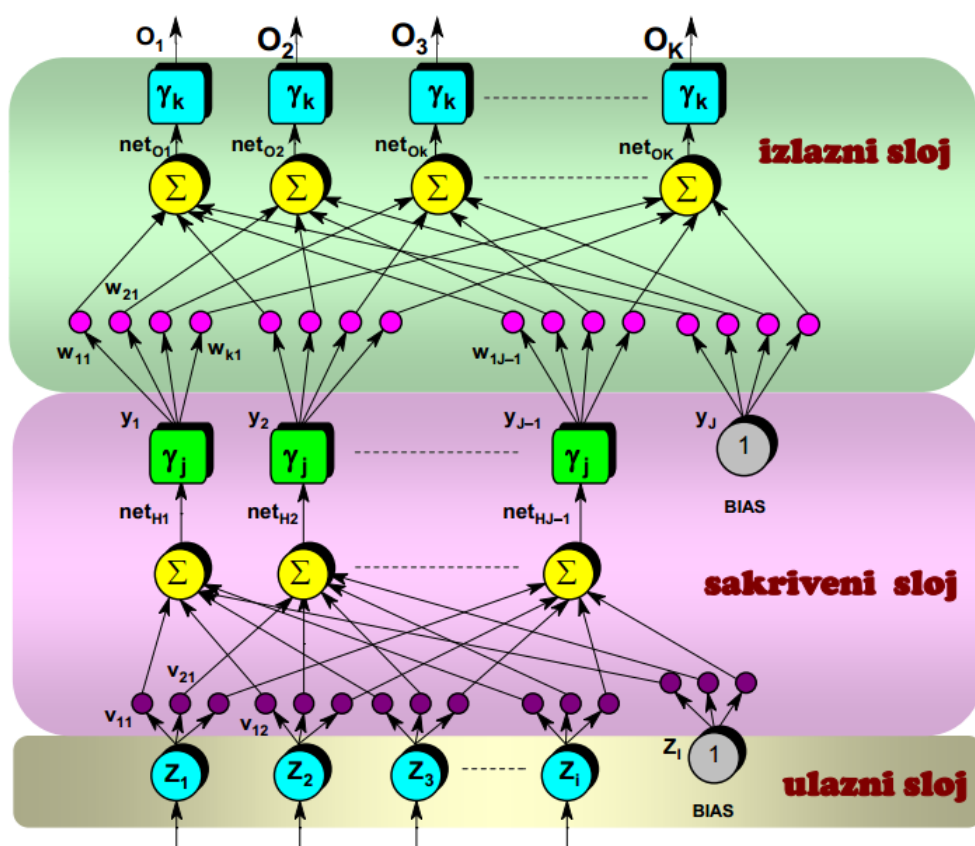
Statička unaprijedna višeslojna mreža sastoji se od neurona povezanih u slojeve, koji su međusobno povezani vezama s težinskim koeficijentima. Na slici 5.4 prikazana je mreža koja se sastoji od ulaznog, izlaznog i skrivenog sloja. Skriveni sloj je sloj koji nije u direktnoj interakciji s okolinom. Broj skrivenih slojeva je proizvoljan, a prema [6] najčešće se koristi jedan do dva sloja.

Parametri statičke unaprijedne neuronske mreže:

- $Z_i$  - ulazi u mrežu,
- $v_{ij}$  - težine veza između ulaznog i skrivenog sloja,
- $w_{kj}$  - težine veza između skrivenog i izlaznog sloja,
- $O_k$  - izlazi iz mreže.
- BIAS - neuroni izlazne vrijednosti jednake jedinici,

Postupak učenja odvija se u dvije faze: **unaprijedna** i **povratna** faza. U principu, učenje mreže svodi se na učenje težinskih koeficijenata koji povezuju slojeve neuronske mreže sve dok se ne postignu željeni izlazi mreže, odnosno dok odstupanje od željene vrijednosti ne bude manje od zadane pogreške učenja. Kroz učenje, promjena parametara težinskih koeficijenata mreže u jednom koraku provodi se onoliko puta koliko ima ulazno izlaznih parova u skupu za učenje. Promjena parametara ovom procedurom naziva se *pattern* ili *stochastic* procedura.





Slika 5.4: Model statičke unaprijedne neuronske mreže

### 5.2.1 Unaprijedna faza učenja

U **unaprijednoj** fazi učenja mreže iz skupa za učenje uzimaju se vrijednosti ulaza mreže  $\mathbf{Z}$  te se izračunavaju vrijednosti izlaza mreže  $\mathbf{O}$ , koji se kasnije uspoređuju s izlaznim vrijednostima  $\mathbf{d}$ , vrijednostima koje izlaz iz mreže pokušava aproksimirati. Za izračunavanje potrebno je zadati početne vrijednosti težina mreže,  $\mathbf{W}$  i  $\mathbf{V}$ , koje se zadaju generatorom slučajnih brojeva. Prema [6], ako su vrijednosti skupa učenja normirane između -1 i 1, i vrijednosti težina potrebno je generirati u tom intervalu. Slijedi primjer unaprijedne faze učenja prema slici 5.4.

Ulazi  $\mathbf{Z}$ , pomnoženi težinama  $\mathbf{V}$ , ulaze u sumatore skrivenog sloja. Za skriveni sloj, funkcija sume izračunava se na sljedeći način:

$$net_{Hj} = \sum_{i=1}^I v_{ji} z_i \quad (5.4)$$

$$j = 1, 2, \dots, J-1, i = 1, 2, \dots, I$$

gdje je:

$H$  - oznaka sloja,

$I$  - broj ulaznih neurona + 1,

$J$  - broj neurona u skrivenom sloju + 1 (bias).

Za aktivacijsku funkciju odabrana je nelinearna bipolarna sigomidalna funkcija (slika 5.3). Slijede izlazi neurona skrivenog sloja:

$$y_j = \frac{2}{1 + e^{-net_{Hj}}} \quad (5.5)$$

$$y_J = 1(bias) \quad (5.6)$$

Vrijednosti izlaznog sloja preko težina  $\mathbf{W}$  spojene su na ulaz svakog neurona izlaznog sloja. Funkcija sume izlaznog sloja izračunava se na sljedeći način:

$$net_{Ok} = \sum_{j=1}^J w_{kj} y_j \quad (5.7)$$

$$k = 1, 2, \dots, K$$

gdje je:

$K$  - broj neurona izlaznog sloja,

$y$  - izlaz iz aktivacijskih funkcija skrivenog sloja.

Za aktivacijsku funkciju izlaznog sloja koristi se linearna funkcija koja omogućuje vrijednosti izlaza mreže veće od 1. Slijedi izlaz mreže:

$$O_k = K_p net_{Ok} \quad (5.8)$$

gdje je  $K_p$  nagib linearne aktivacijske funkcije. U nastavku se uzima  $K_p = 1$ .

### 5.2.2 Povratna faza učenja

U **povratnoj** fazi učenja, ostvareni izlazi iz mreže,  $\mathbf{O}$ , i željeni izlazi iz mreže,  $\mathbf{d}$ , uspoređuju se te se na temelju razlike izračunava greška učenja, prema kojoj se vrši promjena parametara težina  $\mathbf{V}$  i  $\mathbf{W}$ . Za svaki ulazno-izlazni par postupak se ponavlja dok greška učenja ne bude manja ili jednaka željenoj koju određuje sam učitelj. Prema [6], najčešće korištena funkcija mjere odstupanja je suma kvadrata pogreške:

$$E = \frac{1}{2} \sum_{n=1}^N (d_n - O_n)^2 \quad (5.9)$$

gdje je  $N$  broj uzoraka u skupu za učenje.  $\frac{1}{2}$  u (5.9) pojednostavljuje derivaciju funkcije cilja (mjere odstupanja) koja teži minimumu.

Nakon izračuna mjere odstupanja, vrši se adaptacija težinskih koeficijenata ( $\vartheta$ ):

$$\vartheta(n+1) = \vartheta(n) + \Delta\vartheta(n) \quad (5.10)$$

gdje je:

$n$  - trenutni korak učenja,

$\Delta\vartheta(n)$  - veličina promjene parametara,

$\vartheta(n+1)$  - nova vrijednost parametara učenja (težina  $w$  i  $v$ ).

Postoji mnogo algoritama za izračunavanje promjene  $\Delta\vartheta(n)$  parametra, u ovom radu detaljnije su objašnjeni algoritam povratnog rasprostiranja pogreške i Levenberg - Marquardt algoritam.

### 5.2.3 Algoritam povratnog rasprostiranja pogreške (Error Back Propagation)

Algoritam povratnog prostiranja pogreške (*eng. Error Back-Propagation Algorithm*) je jednostavna metoda za izračunavanje gradijenta pogreške s obzirom na parametre učenja. Promjena parametara učenja odvija se u suprotnom smjeru od toka signala.

Pogrešku  $E(\vartheta)$  moguće je u okolišu točke  $\vartheta$  aproksimirati s prva dva člana Taylorovog reda:

$$E(\vartheta + \Delta\vartheta) \approx E(\vartheta) + \Delta E(\vartheta) \quad (5.11)$$

$$\Delta E(\vartheta) = \Delta\vartheta^T \nabla E(\vartheta) \quad (5.12)$$

$$\nabla E(\vartheta) = \frac{\partial E(\vartheta)}{\partial \vartheta} \quad (5.13)$$

Izraz (5.13) je gradijent pogreške, za koji je cilj da se smanjuje najvećim mogućim iznosom. Gradijent pogreške predstavlja smjer najbrže promjene pogreške te je pogrešku potrebno smanjiti za najveći mogući iznos, odnosno, potrebno je odrediti  $\Delta(\vartheta)$  za koji  $\Delta E(\vartheta)$  poprima najveći negativni iznos:

$$\Delta\vartheta = -\eta \nabla E(\vartheta) \quad (5.14)$$

gdje je  $\eta$  koeficijent brzine učenja koji određuje učitelj, prema [6] između  $10^{-3}$  i 10, koji omogućuje utjecaj na veličinu koraka parametara učenja. Potrebno je procijeniti optimalan iznos koeficijenta brzine učenja, jer odabirom malog koeficijenta učenja usporava se učenje i time se povećava mogućnost zaglavljivanja u lokalnom minimumu. U suprotnom, odabirom velikog koeficijenta brzine učenja ubrzava se učenje, ali se povećava mogućnost preksakivanja minimuma.

Uvrštavanjem (5.14) u (4.10) dobiva se algoritam za izračunavanje promjena težina mreže:

$$\vartheta(n+1) = \vartheta(n) - \eta \nabla E(\vartheta(n)) \quad (5.15)$$

Za učenje EBP algoritmom potreban je velik broj potrebnih iteracija da bi se greška smanjila na željenu vrijednost, da bi se umanjio taj problem i ostali problemi tipični za EBP algoritam, radi se modifikacija algoritma dodavanjem **momentuma** prema (5.16):

$$\Delta \vartheta = -\eta \nabla E(\vartheta) + \alpha \Delta \vartheta(n-1) \quad (5.16)$$

Vrijednost koeficijenta momentuma  $\alpha$  određuje učitelj, prema [6] bira se u intervalu između 0.1 i 0.9. Momentum skalira promjenu parametara učenja u prethodnom koraku se dodaje u izraz za promjenu u sadašnjem koraku. Slijedi promjena parametara učenja s momentumom:

$$\vartheta(n+1) = \vartheta(n) - \eta \nabla E(\vartheta(n)) + \alpha \Delta \vartheta(n-1) \quad (5.17)$$

Postoje i modifikacije EBP algoritma dodavanjem još jednog momentuma (momentuma drugog reda), zatim uvođenje adaptivnog koeficijenta učenja, no ove modifikacije neće se detaljno obraditi u ovom radu.

Slijedi promjena parametara učenja od izlaznog prema skrivenom sloju. Prvo se mijenjaju težinski faktori između izlaznog i skrivenog sloja,  $\mathbf{W}$ :

$$w_{kj}(n+1) = w_{kj}(n) - \eta \nabla E((n)) + \alpha \Delta w_{kj}(n-1) \quad (5.18)$$

Izraz za gradijent pogreške:

$$\nabla E(n) = \frac{\partial E(n)}{\partial w_{kj}} = \frac{\partial E(n)}{\partial O_k} \frac{\partial O_k}{\partial net_{Ok}} \frac{\partial net_{Ok}}{\partial w_{kj}} \quad (5.19)$$

Prema [6] uvodi se karakteristična vrijednost algoritma povratnog prostiranja pogreške,  $\delta$ :

$$\delta = -\frac{\partial E(n)}{\partial net} \quad (5.20)$$

Iz (5.9) slijedi:

$$\frac{\partial E(n)}{\partial O_k} = -(d_k - O_k) \quad (5.21)$$

Iz (5.8) slijedi:

$$\frac{\partial O_k}{\partial net_{Ok}} = 1 \quad (5.22)$$

Iz (5.19) do (5.22) slijedi izraz za  $\delta$ :

$$\delta_{Ok} = d_k - O_k \quad (5.23)$$

Iz (5.7) slijedi:

$$\frac{\partial net_{Ok}}{\partial w_{kj}} = y_j \quad (5.24)$$

Uvrštavanjem (5.21), (5.22) i (5.23) u (5.19) slijedi:

$$\nabla E(n) = \frac{\partial E(n)}{\partial w_{kj}} = -(d_k - O_k)y_j = \delta_{Ok}y_j \quad (5.25)$$

Slijedi konačni algoritam promjene težina izlaznog sloja uvrštavanjem (5.25) u (5.18):

$$w_{kj}(n+1) = w_{kj}(n) + \eta \delta_{Ok}y_j + \alpha \Delta w_{kj}(n-1) \quad (5.26)$$

Nakon promjene težina izlaznog sloja, slijedi promjena težina sakrivenog sloja,  $\mathbf{V}$ :

$$v_{ji}(n+1) = v_{ji}(n) - \eta \nabla E(n) + \alpha \Delta v_{ji}(n-1) \quad (5.27)$$

Slijedi izračun gradijenta pogreške:

$$\nabla E(n) = \frac{\partial E(n)}{\partial v_{ji}} = \frac{\partial E(n)}{\partial y_j} \frac{\partial y_j}{\partial net_{Hj}} \frac{\partial net_{Hj}}{\partial v_{ji}} \quad (5.28)$$

Na promjenu svake težine skrivenog sloja utječu svi neuroni u izlaznom sloju, stoga slijedi:

$$\frac{\partial E(n)}{\partial y_j} = \sum_{k=1}^K \frac{\partial E(n)}{\partial O_k} \frac{\partial O_k}{\partial net_{Ok}} \frac{\partial net_{Ok}}{\partial y_j} \quad (5.29)$$

gdje je  $K$  broj neurona izlaznog sloja. Također slijedi:

$$\frac{\partial E(n)}{\partial O_k} = -(d_k - O_k) \quad (5.30)$$

$$\frac{\partial O_k}{\partial net_{Ok}} = 1 \quad (5.31)$$

$$\frac{\partial net_{Ok}}{\partial y_j} = w_{kj} \quad (5.32)$$

Uvrštavanjem (5.30) - (5.32) u (5.29) slijedi:

$$\frac{\partial E(n)}{\partial y_j} = - \sum_{k=1}^K (d_k - O_k) w_{kj} \quad (5.33)$$

odnosno uvrštavanjem (5.23) u (5.33) slijedi:

$$\frac{\partial E(n)}{\partial y_j} = - \sum_{k=1}^K \delta_{Ok} w_{kj} \quad (5.34)$$

Iz (5.5) slijedi:

$$\frac{\partial y_j}{\partial net_{Hj}} = \frac{1}{2}(1 - y_j^2) \quad (5.35)$$

te iz (5.4):

$$\frac{\partial net_{Hj}}{\partial v_{ji}} = Z_i \quad (5.36)$$

Slijedi konačni oblik algoritma promjene težina skrivenog sloja:

$$v_{ji}(n+1) = v_{ji}(n) + \frac{1}{2}\eta(1 - y_j^2)Z_i \left( \sum_{k=1}^K \delta_{Ok} w_{kj} \right) + \alpha \Delta v_{ji}(n-1) \quad (5.37)$$

#### 5.2.4 Levenberg - Marquardt algoritam

Levenberg - Marquardt algoritam je najčešće korištena metoda u području nelinearne optimizacije. Kombinacijom dobrih strana obične gradijentne metode i Gauss - Newtonove metode cilj je pronaći minimum funkcije cilja u što manjem broju koraka. Jedan od nedostataka EBP algoritma je nedostatak informacije o obliku funkcije pogreške (drugoj derivaciji po parametrima učenja), poznata je samo informacija o samom gradijentu (prva derivacija pogreške po parametrima učenja), što nije slučaj za Levenberg- Marquardtov algoritam.

Slijedi aproksimacija kvadratične funkcije pogreške u okolini minimuma funkcije prema Gauss-Newtonovoj metodi:

$$\vartheta(n+1) = \vartheta(n) - [\nabla^2 E(n)]^{-1} \nabla E(n) \quad (5.38)$$

gdje  $\nabla^2 E(n)$  predstavlja drugu derivaciju pogreške po parametrima učenja, tzv. Hessian matricu. Kako je često puta drugu derivaciju teško izračunati, koristi se aproksimacija Hessianove matrice dobivena pomoću umnoška gradijenta pogreške po parametrima učenja (prvih derivacija). Gradijent pogreške  $\nabla E(n)$  računa se na sljedeći način:

$$\nabla E(n) = J^T(n) \cdot e(n) \quad (5.39)$$

te se Hessianova matrica računa prema:

$$\nabla^2 E(n) = J^T(n) \cdot J(n) \quad (5.40)$$

gdje je  $e$  vektor pogreške,  $J$  Jacobian matrica (matrica derivacije pogreške po parametrima

učenja). Slijedi izračun poregške  $e$ :

$$e = \sum_{n=1}^N \sum_{k=1}^K (d_{kn} - O_{kn}) \quad (5.41)$$

gdje je:

$N$  - broj redaka skupa za učenje,

$K$  - broj izlaznih neurona mreže.

Dimenzije željenog i stvarnog izlaza mreže su  $\dim(d_n) = \dim(O_n) = [1 \times K]$ , dok je dimenzija vektora pogreške  $\dim(e) = [N \times 1]$ .

Jacobianova matrica sadrži derivacije pogreške po parametrima učenja. Mreža uči tri različita vektora parametara - težine sakrivenog i izlaznog sloja te nagib sigmoidalne aktivacijske funkcije. Slijedi oblik Jacobianove matrice u općenitom obliku:

$$J(\mathbf{w}) = \begin{bmatrix} \frac{\partial e_1}{\partial w_1} & \frac{\partial e_1}{\partial w_2} & \frac{\partial e_1}{\partial w_3} & \dots & \frac{\partial e_1}{\partial w_P} \\ \frac{\partial e_2}{\partial w_1} & \frac{\partial e_2}{\partial w_2} & \frac{\partial e_2}{\partial w_3} & \dots & \frac{\partial e_2}{\partial w_P} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N}{\partial w_1} & \frac{\partial e_N}{\partial w_2} & \frac{\partial e_N}{\partial w_3} & \dots & \frac{\partial e_N}{\partial w_P} \end{bmatrix} \quad (5.42)$$

Dimenzija Jacobiana je  $\dim(J) = [N \times P]$ , gdje je:

$N$  - broj redaka (uzoraka) skupa za učenje,

$P$  - broj elemenata vektora određenog parametra učenja.

U ovom radu korištena je troslojna unaprijedna neuronska mreža, gdje je ukupan broj neurona ulaznog sloja  $I$ , ukupan broj neurona skrivenog sloja  $J$  te ukupan broj neurona izlaznog sloja  $K$ , prema čemu slijede dimenzije parametara učenja, s uključenim biasima:

$$\dim(\mathbf{w}) = [K \times J] \quad (5.43)$$

$$\dim(\mathbf{v}) = [J \times I] \quad (5.44)$$

$$\dim(\mathbf{c}) = [1 \times (J - 1)] \quad (5.45)$$

gdje je  $\mathbf{c}$  vektor nagiba nelinearne bipolarne sigmoidalne aktivacijske funkcije. U teorij-skoj razradi Levenberg - Marquardtova algoritma kao parametar koji se uči uzima se i nagib funkcije, ali u primjeni mreža u ovom radu nagib funkcije nije parametar učenja. U program-skom paketu MATLAB nelinearna bipolarna sigmoidalna aktivacijska funkcija definirana je naredbom *tansig* u kojoj je nagib funkcije konstantan i iznosi 2, te je tako uzeto i u treniranju mreža.

Ukoliko se matrice  $\mathbf{w}$  i  $\mathbf{v}$  zapišu u vektorskom obliku slijedi:

$$\dim(\mathbf{w}) = [1 \times K \cdot J] \quad (5.46)$$

$$\dim(\mathbf{v}) = [1 \times (J - 1) \cdot I] \quad (5.47)$$

Slijede dimenzije Jacobijevih matrica prema vektorima parametara  $\mathbf{w}, \mathbf{v}$  i  $\mathbf{c}$ :

$$\dim(J(\mathbf{w})) = [N \times K \cdot J] \quad (5.48)$$

$$\dim(J(\mathbf{v})) = [N \times (J - 1) \cdot I] \quad (5.49)$$

$$\dim(J(\mathbf{c})) = [N \times (J - 1)] \quad (5.50)$$

Elementi Jacobijanove matrice određuju se analogno određivanju gradijenta sume kvadrata pogreške po parametrima učenjima opisanim u prethodnom potpoglavlju, no umjesto derivacije sume kvadrata pogreške vrši se derivacija pogreške  $e$  po parametrima učenja.

Za težine izlaznog sloja, element Jacobijanove matrice  $J(\mathbf{w})$  računa se na sljedeći način:

$$\frac{\partial e_k}{\partial w_{kj}} = \frac{\partial e_k}{\partial O_k} \frac{\partial O_k}{\partial net_{Ok}} \frac{\partial net_{Ok}}{\partial w_{kj}} = -1 \cdot 1 \cdot y_j. \quad (5.51)$$

te iz toga slijedi:

$$J(\mathbf{w}) = \begin{bmatrix} -y_1^{(1)} & -y_2^{(1)} & \cdots & -y_J^{(1)} & | & -y_1^{(1)} & -y_2^{(1)} & \cdots & -y_J^{(1)} & | & \cdots \\ -y_1^{(2)} & -y_2^{(2)} & \cdots & -y_J^{(2)} & | & -y_1^{(2)} & -y_2^{(2)} & \cdots & -y_J^{(2)} & | & \cdots \\ \vdots & \vdots & \ddots & \vdots & | & \vdots & \vdots & \ddots & \vdots & | & \ddots \\ -y_1^{(N)} & -y_2^{(N)} & \cdots & -y_J^{(N)} & | & -y_1^{(N)} & -y_2^{(N)} & \cdots & -y_J^{(N)} & | & \cdots \end{bmatrix} \quad (5.52)$$

Uzduž svakog retka pojavljuju se sekvence koje se razlikuju od retka do retka. Koliko ima neurona skrivenog sloja, s uključenim bias neuronom, toliko će biti elemenata u jednoj sekvenci, dok će sekvenci biti onoliko koliko ima neurona izlaznog sloja.

Slijedi element Jacobijanove matrice  $J(\mathbf{v})$ :

$$\frac{\partial e}{\partial v_{ji}} = \frac{\partial e}{\partial y_j} \frac{\partial y_j}{\partial net_{H_j}} \frac{\partial net_{H_j}}{\partial v_{ji}} \quad (5.53)$$

Pogreška  $e$  u gornjem izrazu je ukupna pogreška izlaznog sloja te djeluje na svaki neuron skrivenog sloja. Drugi razlomak s desne strane dan je izrazom 5.35, dok je treći razlomak dan izrazom 5.36. Prvi razlomak jednak je jednak:



$$\frac{\partial e}{\partial y_j} = \sum_{k=1}^K \frac{\partial e}{\partial O_k} \frac{\partial O_k}{\partial net_{O_k}} \frac{\partial net_{O_k}}{\partial v_{ji}} = - \sum_{k=1}^K w_{kj} \quad (5.54)$$

Slijedi konačni izraz za određivanje elementa matrice  $J(\mathbf{v})$  uvrštavanjem izraza 5.54, 5.35 i 5.36 u 5.53:

$$\frac{\partial e}{\partial v_{ji}} = - \sum_{k=1}^K w_{kj} \cdot \frac{1}{2} (1 - y_j) \cdot Z_i \quad (5.55)$$

Vidljivo je da element matrice  $J(\mathbf{v})$  ovisi o dva indeksa,  $j$  i  $i$ , pri čemu se prvo mijenja  $i$ , pa zatim  $j$ . Slijedi pojednostavljeni oblik matrice  $J(\mathbf{v})$ :

$$J(\mathbf{v}) = \begin{bmatrix} \frac{\partial e^{(1)}}{\partial v_{11}} & \frac{\partial e^{(1)}}{\partial v_{12}} & \dots & \frac{\partial e^{(1)}}{\partial v_{1I}} & \frac{\partial e^{(1)}}{\partial v_{21}} & \frac{\partial e^{(1)}}{\partial v_{22}} & \dots & \frac{\partial e^{(1)}}{\partial v_{2I}} & \dots & \frac{\partial e^{(1)}}{\partial v_{J*1}} & \frac{\partial e^{(1)}}{\partial v_{J*2}} & \dots & \frac{\partial e^{(1)}}{\partial v_{J*I}} \\ \frac{\partial e^{(2)}}{\partial v_{11}} & \frac{\partial e^{(2)}}{\partial v_{12}} & \dots & \frac{\partial e^{(2)}}{\partial v_{1I}} & \frac{\partial e^{(2)}}{\partial v_{21}} & \frac{\partial e^{(2)}}{\partial v_{22}} & \dots & \frac{\partial e^{(2)}}{\partial v_{2I}} & \dots & \frac{\partial e^{(2)}}{\partial v_{J*1}} & \frac{\partial e^{(2)}}{\partial v_{J*2}} & \dots & \frac{\partial e^{(2)}}{\partial v_{J*I}} \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \dots & \vdots & \dots & \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e^{(2)}}{\partial v_{11}} & \frac{\partial e^{(2)}}{\partial v_{12}} & \dots & \frac{\partial e^{(2)}}{\partial v_{1I}} & \frac{\partial e^{(2)}}{\partial v_{21}} & \frac{\partial e^{(2)}}{\partial v_{22}} & \dots & \frac{\partial e^{(2)}}{\partial v_{2I}} & \dots & \frac{\partial e^{(2)}}{\partial v_{J*1}} & \frac{\partial e^{(2)}}{\partial v_{J*2}} & \dots & \frac{\partial e^{(2)}}{\partial v_{J*I}} \end{bmatrix} \quad (5.56)$$

Slijedi element Jacobieve matrice  $J(\mathbf{c})$ , koja sadrži derivacije pogreške po nagibu sigmoidalne funkcije:

$$\frac{\partial e}{\partial c_j} = \frac{\partial e}{\partial y_j} \frac{\partial y_j}{\partial c_j} \quad (5.57)$$

Za desni razlomak jednadžbe vrijedi:

$$\frac{\partial y_j}{\partial c_j} = \frac{1}{2} net(1 - y_j^2) \quad (5.58)$$

dok je lijevi razlomak dan jednadžbom 5.54. Stoga slijedi:

$$\frac{\partial e}{\partial c_j} = \sum_{k=1}^K w_{kj} \cdot net_{Hj} \cdot (1 - y_j^2) \frac{1}{2} net(1 - y_j^2) \quad (5.59)$$

Pojednostavljeni zapis Jacobijeve matrice  $J(\mathbf{c})$ :

$$J(\mathbf{c}) = \begin{bmatrix} \frac{\partial e^{(1)}}{\partial c_1} & \frac{\partial e^{(1)}}{\partial c_2} & \dots & \frac{\partial e^{(1)}}{\partial c_{J-1}} \\ \frac{\partial e^{(2)}}{\partial c_1} & \frac{\partial e^{(2)}}{\partial c_2} & \dots & \frac{\partial e^{(2)}}{\partial c_{J-1}} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e^{(N)}}{\partial c_1} & \frac{\partial e^{(N)}}{\partial c_2} & \dots & \frac{\partial e^{(N)}}{\partial c_{J-1}} \end{bmatrix} \quad (5.60)$$

Jednadžba 5.63 je Gauss-Newtonova metoda, dok je jednadžba 5.15 gradijentna metoda za promjenu parametra učenja. Dvije navedene metode potrebno je spojiti u jedan izraz, Levenberg - Marquardtovu metodu promjene parametara učenja:

$$\vartheta(n+1) = \vartheta(n) - (\nabla^2 E(n) + \lambda \mathbf{I})^{-1} \nabla E(n) \quad (5.61)$$


gdje je  $\lambda$  koeficijent brzine učenja gradijentne metode, koji se množi jediničnom matricom radi približavanja Hessianovoj matrici. Ukoliko je pogreška velika (nalazi se daleko od minimuma), koristi se gradijentna metoda, koeficijent  $\lambda$  je velik. Ukoliko je pogreška mala (nalazi se blizu minimuma) koristi se Gauss-Newtonova metoda, koeficijent  $\lambda$  je malog iznosa. Koeficijent  $\lambda$  u ovom slučaju je promjenjivog iznosa te se povećava ili smanjuje ovisno o iznosu pogreške učenja.

### 5.3 Aproksimacija pomaka na temelju mjerenog napona

Prva primjena umjetne neuronske mreže kod piezoelektričnih pretvornika za skup učenja koristi podatke iz eksperimenta 1, poglavlje 3. Ulaz u neuronsku mrežu je mjereni napon (slika 3.6). Kako jedno snimanje napona sadrži 100200 uzoraka, postoji 12 snimaka, što rezultira s ukupno 1202400 uzoraka, odnosno ulaza u mrežu. S obzirom na sinusnu karakteristiku signala, moguće je reducirati broj uzoraka a da se zadrže sve važne karakteristike signala (amplituda, fazni pomak). Broj uzoraka reduciran je na 600 uzoraka po snimanju (u obzir je uzet svaki 167. uzorak), što rezultira s 7200 uzoraka ukupno. Na isti princip reduciran je i željeni izlaz iz mreže, mjereni pomak (slika 3.9).

Cilj treniranja neuronske mreže s ovim skupom učenja je pronalazak jednostavnog načina određivanja relevantnih parametara na temelju kojih je moguće uočiti zamor materijala, trošenje, lom ili neki drugi oblik kvara pretvornika. Kao što je ranije rečeno analizom rezultata ovog eksperimenta, smatra se da je došlo do zamora materijala kada amplituda pomaka padne na 80% početne vrijednosti. Za mjerenje amplitude pomaka potreban je laserski vibrometar ili neki drugi oblik senzora pomaka ili brzine, koji nije uvijek dostupan korisnicima piezoelektričnih pretvornika. Zato je jednostavniji način mjerenje senzorskog napona, te na temelju mjerenja, korištenjem umjetne neuronske mreže, doći do iznosa amplitude pomaka.

Za treniranje ove neuronske mreže korišten je toolbox softverskog paketa MATLAB, Neural Network Fitting Tool (*nftool*). Na slici 5.5 prikazana je topologija korištene mreže. Mreža je unaprijedna, uz ulazni i izlazni sloj sadrži jedan sakriveni sloj s 10 neurona. Aktivacijska funkcija skrivenog sloja je sigmoidalna, opisana jednadžbom (5.3), dok je aktivacijska funkcija izlaznog sloja linearna. Na ulazu svakog neurona korišten je i ulaz jedinične vrijednosti, *bias*. Treniranje mreže odvija se promjenom izlaznih i skrivenih težina prema povratnom prostiranju pogreške, te se za promjenu parametara kroz učenje koristi Levenberg-Marquardtov algoritam.

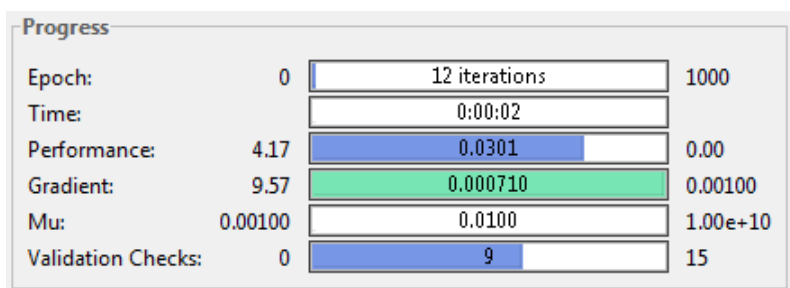


Slika 5.5: Topologija trenirane statičke neuronske mreže

Generirane su vrijednosti početnih težina između -1 i 1 te je zadano ograničenje od maksimalno 1000 iteracija. Algoritam završava treniranje neuronske mreže kada postigne maksimalan broj iteracija ili, ukoliko je zadano, maksimalno vrijeme treniranja. Prije treniranja zadaje se i parametar kojim se ocjenjuje točnost treniranja, odnosno parametar performanse (*eng. performance*), funkcijom *net.performFcn*. Kao procjena točnosti algoritma tokom treniranja uzima se srednja kvadratna greška definirana sljedećim izrazom:

$$MSE = \frac{\sum_{n=1}^N (d_n - O_n)^2}{N} \quad (5.62)$$

Algoritam treniranja se također zaustavlja kada promjena srednje kvadratne greške između prethodnog i trenutnog koraka učenja, odnosno gradijent srednje kvadratne pogreške, padne ispod zadane vrijednosti od  $10^{-3}$ . Također je moguće odrediti parametar provjere valjanosti (*eng. validation checks*) koji predstavlja broj uzastopnih iteracija u kojima se iznos srednje vrijednost kvadratne greške ne smanjuje. Ovaj parametar podešen je na 15 uzastopnih iteracija. Parametar  $\lambda$ , koeficijent brzine učenja Levenberg-Marquardt algoritma, podešen je na početnu vrijednost od 0,001. Ovaj parametar mijenja se ovisno o pogrešci učenja, te sukladno tome raste ili pada za određeni iznos. Skup učenja sastoji se 7200 uzoraka, jedan uzorak sadrži jedan ulaz - napon, i jedan izlaz - pomak. Prije treniranja, ulazni i izlazni parametri normirani su između vrijednosti -1 i 1, s obzirom da je aktivacijska funkcija sigmoidalna koja izvan raspona ovih vrijednosti ulazi u zasićenje te su u rasponu tih vrijednosti generirane i početne težine. U nastavku slijede rezultati treniranja.



Slika 5.6: Parametri treniranja mreže

Da bi vrijednost gradijenta pogreške bila manja od  $10^{-3}$ , statičkoj mreži s 10 skrivenih neurona bilo je potrebno 12 koraka učenja (slika 5.6).

Kao procjena točnosti naučenog algoritma učenja (*eng. performance*) koristi se normalizirani korijen srednje kvadratne pogreške (NRMS):


$$NRMS = \frac{RMS}{\sigma_{d_n}} = \frac{\sqrt{\frac{\sum_{n=1}^N (d_n - O_n)^2}{N}}}{\sigma_{d_n}} \quad (5.63)$$

gdje je:

$$\sigma_{d_n} = \sqrt{\frac{1}{N} \sum_{n=1}^N (d_n - \bar{d})^2} \quad (5.64)$$

$$\bar{d} = \frac{1}{N} \sum_{n=1}^N d_n \quad (5.65)$$


Na slici 5.7 prikazana je usporedba mjerenog signala pomaka kroz cijeli skup učenja s dobivenim izlazima iz mreže. Vrijednost NRMS parametra iznosi 0,34. Ukoliko bi se prije treniranja smanjio iznos zadanog gradijenta pogreške kojim se zaustavlja treniranje čak i do iznosa  $10^{-10}$ , značajnije promjene nisu postignute.



Slika 5.7: Usporedba mjerenog i izlaznog signala


Na slici 5.8 pobliže je prikazan graf u području amplitudnih vrijednosti. Iako se može primjetiti relativno dobro aproksimiranje sinusne karakteristike signala mreže, vidljivo je da u području amplitudnih vrijednosti dolazi do vrlo loše aproksimacije. U jednom snimanju

mjerenja amplitudna vrijednost napona je konstantna, dok je amplitudna vrijednost pomaka u jednom snimanju promjenjiva. Dolazi se do zaključka da je potrebno aproksimirati dinamički sustav, a korištena je statička neuronska mreža. Ipak, statičkom neuronskom mrežom, prema [6], moguće je aproksimirati dinamičko ponašanje sustava.




Slika 5.8: Usporedba mjerenog i izlaznog signala kod amplitudnih vrijednosti

Broj ulaznih neurona statičke mreže koja opisuje dinamičko ponašanje sustava trebao bi biti jednak redu sustava čije se ponašanje uči. S obzirom da je red sustava nepoznat, aproksimirat će se članom prvog reda, odnosno mreža će u skupu za treniranje imati dva ulaza, napon u koraku  $n$ ,  $Z(n)$  te mjereni pomak u koraku  $n - 1$ ,  $d(n - 1)$ . Ostali parametri jednaki su prethodno treniranoj mreži. Slijedi analiza trenirane mreže.



Slika 5.9: Usporedba mjerenog i izlaznog signala


NRMS vrijednost koja u obzir uzima mjereni pomak i izlaz trenirane mreže iznosi 0,02, što je zadovoljavajuć iznos, odnosno trenirana mreža je s dovoljnom točnošću aproksimirala dinamiku pomaka na temelju dva ulaza po uzorku. U usporedbi s vrijednosti NRMS parametra u prethodnom treniranju u vrijednosti od 0,34, lako je zaključiti da je došlo do znatnog poboljšanja aproksimacije što je vidljivo i na vrijednosti parametra koji pokazuje točnost mreže. Vrijednost NRMS parametra nije uvijek odlučujuć faktor u određivanju aproksimira li trenirana mreža dovoljno dobro željeni izlaz, već treba i vizualno analizirati dobivene vrijednosti. Primjerice, moguće je da mreža aproksimira mjereni izlaz sa željenom točnošću duž cijelog područja, osim u području krajnjih (ili amplitudnih) vrijednosti. Ukoliko je za određenu primjenu područje krajnjih vrijednosti zanemarivo, odnosno nije od velikog značaja, vrijednost NRMS parametra u iznosu od 0,34 može biti dovoljno točno. No, kako je za ovu primjenu vrlo bitan upravo iznos krajnjih odnosno amplitudnih vrijednosti pomaka, poželjno je da vrijednost NRMS parametra bude što manja, te da aproksimacija u području amplitudnih vrijednosti bude što točnija. Aproksimacija amplitudnih vrijednosti korištenjem statičke mreže s dva ulaza detaljno je vidljiva na slici 5.10.




Slika 5.10: Usporedba mjerenog i izlaznog signala kod amplitudnih vrijednosti

Da bi se naučena mreža mogla testirati, potreban je set ulaznih podataka koji nisu bili uključeni u treniranje. No kako nije izvedeno mjerenje u ovu svrhu na drugom piezoelektričnom pretvorniku istog tipa te kako postoji samo 12 snimanja, za testiranje mreže koristit će se ulazni podaci korišteni za prethodno treniranje iste mreže, s jednom razlikom. Kao ulaz u mrežu, uz mjereni napon, neće se koristiti mjereni pomak u prethodnom koraku,  $d(n-1)$ , već izlaz iz testirane mreže u prethodnom koraku,  $O(n-1)$ , prikazano na slici 5.11. Dakle, testiranje mreže odvija se provođenjem unaprijedne faze kroz cijeli skup za učenje. Unaprijedna faza

prikazana je slikom 5.4. Prolaskom kroz cijeli skup za učenje težine ostaju nepromijenjene, a njihov iznos dobiven je iz prethodno trenirane mreže. Slijede rezultati testiranja.



Slika 5.11: Blok shema testiranja mreže



Slika 5.12: Usporedba mjerenog i izlaznog signala kod amplitudnih vrijednosti

Naknadnim testiranjem parametar NRMS iznosi 0,24, što je nezadovoljavajuć rezultat. Iako se određeni iznos numeričke greške unosi množenjem izlaza da bi se nakon normiranja vratio u stvarne vrijednosti, svejedno je vidljivo neuspješno aproksimiranje amplitudnih vrijednosti (slika 5.12). Iako je u principu moguće za dinamički sustav koristiti statičku mrežu, u ovom slučaju uputno je korištenje dinamičke mreže koja u ovom radu nije obrađivana. Jedna od korisnih prednosti dinamičke mreže u ovom slučaju je činjenica da nije potrebno unaprijed znati red sustava, kao što je to slučaj za statičku mrežu. Statička mreža uspješno bi izvršila zadatak ukoliko bi se, uz napon, mjerio još jedan signal za koji nije potrebna skupocjena dodatna oprema, poput struje koja je rezultat generiranja naboja na elektrodama piezoelektričnog pretvornika.

## 5.4 Aproksimacija rezonantne frekvencije i ekvivalentnog otpora


Treniranje sljedeće umjetne neuronske mreže prodeveno je na temelju eksperimenta 3 opisanog u potpoglavlju 3.4. Ulazni podatci skupa za učenje sastoje se od značajki mjerenog napona izvedenih na slici 3.18. Ulaz jednog uzorka sastoji se od sljedećih značajki, detaljnije opisanih u poglavlju 3.4:

- maksimum,
- efektivna vrijednosti,
- varijanca,
- faktor jasnoće,
- faktor oblika,

dok su za izlaz jednog uzorka iz skupa učenja odabrane sljedeće značajke iz slike 3.19:

- retonantna frekvencija,
- ekvivalentni otpor.

Skup za učenje ima 59 uzoraka. Koristi se jedan skriveni sloj s 10 neurona. Topologija mreže prikazana je na slici 5.13.



Slika 5.13: Topologija mreže

Za treniranje korišten je Levenberg-Marquardtov algoritam s početnim parametrima podešenim jednako kao u prethodnom poglavlju. Ulazi i izlazi prije treniranja skalirani su u rasponu vrijednosti -1 i 1. Slijede rezultati treniranja.


Epoch:	0	82 iterations	1000
Time:		0:00:02	
Performance:	0.152	0.00169	0.00
Gradient:	0.352	9.91e-05	0.000100
Mu:	0.00100	0.000100	1.00e+10
Validation Checks:	0	64	10000

Slika 5.14: Parametri treniranja mreže LM algoritmom


Na prethodnoj slici vidljivo je da je u 82 iteracije gradijent pogreške pao na vrijednost manju od  $10^{-4}$ , stoga je treniranje prekinuto. No, rezultati treniranja nisu zadovoljavajući. NRMS



vrijednost rezonantne frekvencije vrlo je visoka, kao i vrijednost NRMS parametra ekvivalentnog otpora, što je vidljivo i na slikama 5.15 i 5.16.



Slika 5.15: Rezonantna frekvencija




Slika 5.16: Ekvivalentni otpor

Pokušaj treniranja mreže klasičnim EBP algoritmom također ne daje poboljšanje. Topologija mreže treniranja je nepromijenjena, koeficijent brzine učenja  $\eta$  jednak je 0,1, dok je momentum  $\alpha$  jednak 0,5. Slijede rezultati treniranja.


Epoch:	0	1000 iterations	1000
Time:		0:00:08	
Performance:	0.184	0.00682	0.00
Gradient:	0.466	0.00449	0.000100
Validation Checks:	0	0	10000

Slika 5.17: Parametri treniranja mreže EBP algoritmom

Na slici 5.17 prikazani su parametri treniranja, gdje je vidljivo da u 1000 koraka gradijent pogreške nije imao iznos manji od  $10^{-3}$ . Na slikama 5.16 i 5.19 vidljiva je loša aproksimacija oba izlazna signala.



Slika 5.18: Rezonantna frekvencija



Slika 5.19: Ekvivalentni otpor

Iako je vidljivo da LM algoritam u određenoj mjeri bolje aproksimira od klasičnog EBP algoritma, glavni razlog zašto niti jedna od dvije vrste algoritama nije dala zadovoljavajuć rezultat je činjenica da se u ulaznim parametrima značajnije promjene događaju u prvoj polovici snimanja, između prvog i 30. uzorka, dok je u izlaznim parametrima značajnija promjena vidljiva između 30. i 60. uzorka, dok su u tom intervalu ulazne vrijednosti relativno konstantne (vidljivo usporedbom slika 3.18 i 3.19). Razlika u provođenju ovog eksperimenta od ostalih je u generiranom ulaznom signalu, koji u ovom slučaju nije sinusnog oblika već kvadratnog, a s obzirom na dinamiku procesa, zbog oštih rubova u naponskom signalu teško je doći do nekih relevantnih značajki signala koje nisu vidljive u ovim parametrima, a koje se mijenjaju ovisno o promjeni rezonantne frekvencije. Također, u izlaznim signalima vidljiv je skok u vrijednosti oko 40. i 53. mjerenja, stoga bi trebalo provesti snimanja u gušćem periodu od svakih sat vremena, primjerice svakih pola sata nakon što se uoči promjena u frekvenciji. Tada bi se tada mogla uspješno primijeniti umjetna neuronska mreža na ovom skupu podataka za učenje.

## Zaključak

Glavna ideja provedenih eksperimenata, analize i istraživanja je pronalazak jednostavnog načina određivanja razine degradacije, trošenja, zamora materijala ili nekog drugog oblika kvara piezoelektričnog bimorfnog pretvornika, bez prekida rada uređaja i korištenja dodatnih senzora. Sve što je potrebno za određivanje stanja pretvornika je izlazni napon ili struja koji se mogu lako mjeriti i tokom rada. Korištenjem treniranih neuronskih mreža, na temelju lako mjerenih veličina, moguće je aproksimirati stvarni iznos pomaka u svakom trenutku, bez dodatnih senzora pomaka ili brzine. Također, na temelju nekih karakterističnih značajki signala napona, korištenjem trenirane mreže, moguće je aproksimirati stvarne vrijednosti relevantnih parametara poput rezonantne i antirezonantne frekvencije, ekvivalentnog kapaciteta, otpora i slično. Njihovom analizom bi se sa sigurnošću moglo utvrditi točno stanje pretvornika te zakazati pravovremeno održavanje pretvornika i dobiti uvid u iznos preostalih radnih sati prije potrebne zamjene pretvornika. Iako u ovom radu trenirane mreže nisu dale željeni rezultat, postoji mnogo potencijala za napredak primjenom novih ideja, modifikacija mreža i analiza signala.

## Literatura

- [1] [www.piezoproducts.com](http://www.piezoproducts.com)
- [2] I. A. Ivan, M. Rakotondrabe, P. Lutz, N. Chaillet; *Cantilevered Actuators for Micromanipulation and Microassembly Contexts*, Signal Measurement and Estimation Techniques for Micro and Nanotechnology , DOI 10.1007/978-1-4419-9946-7 2, © Springer Science+Business Media, LLC 2011
- [3] J. K. Kimotho, C. Sondermann-Woelke, W. Sextro; *An approach for feature extraction and selection from non-trending data for machinery prognosis*, 2013
- [4] W. Al-Ashtari, M. Hunstig, T. Hemsell and W. Sextro; *Analytical determination of characteristic frequencies and equivalent circuit parameters of a piezoelectric bimorph*, Journal of Intelligent Material Systems and Structures 2012 23: 15 originally published online 14 December 2011
- [5] [www.americanpiezo.com/knowledge-center/piezo-theory/](http://www.americanpiezo.com/knowledge-center/piezo-theory/)
- [6] B. Novaković, D. Majetić, M. Široki; *Umjetne neuronske mreže*, X-Press, Zagreb, 1998.
- [7] D. Majetić; *Neuronske mreže*, podloge za predavanja, 2013.
- [8] H. Yu, B.M. Willamowski; *Industrial Electronics Handbook, Levenberg–Marquardt Training* (12-1 do 12-15 str.), CRC Press, 2011.
- [9] T. Baček; *Neuronske mreže - diplomski rad*, FSB, 2011.